

Eignung von Bestellinformationen zur Prognose zukünftiger Nachfrage und Bestimmung des Entkopplungspunkts



TECHNISCHE
UNIVERSITÄT
DARMSTADT

Vom Fachbereich Rechts- und Wirtschaftswissenschaften
der Technischen Universität Darmstadt

genehmigte Dissertation von
Diplom-Wirtschaftsinformatiker Robert Zander
aus Berlin

Zur Erlangung des akademischen Grades
Doctor rerum politicarum (Dr. rer. pol.)

Referent: Prof. Dr. Herbert Meyr

Korreferent: Prof. Dr. Ralf Elbert

Tag der Einreichung: 09.10.2015

Tag der mündlichen Prüfung: 04.04.2016

Darmstadt 2016

D17

Inhaltsverzeichnis

Abkürzungsverzeichnis	iv
Abbildungsverzeichnis	v
Tabellenverzeichnis	viii
1. Einleitung	1
2. Grundlagen des Supply Chain Managements	7
2.1. Supply Chain Management	7
2.1.1. Hierarchische Planung	10
2.1.2. Supply Chain Planning-Matrix	20
2.2. Planungsmodule der Supply Chain Planning-Matrix	22
2.3. Das Entkopplungspunktkonzept	30
2.4. Bedeutung des Entkopplungspunktkonzepts für das Supply Chain Management	37
2.4.1. Einfluss des Entkopplungspunkts auf die operative Planung	38
2.4.2. Einfluss des Entkopplungspunkts auf das Strategic Network Design	46
2.5. Bedeutung verschiedener Prognosemethoden für das Demand Planning	49
2.6. Zusammenfassung	52
3. Das verallgemeinerte Auftragsprofil	54
3.1. Definition der Variablen	54
3.1.1. Die Bestellung	54
3.1.2. Kumulation von Bestellinformationen	56
3.1.3. Bestellmengen und Aggregation	57
3.1.4. Zeitliche Dimensionierung	58
3.1.5. Einfluss der verwendeten Maßeinheit	60
3.1.6. Anteilige Bestellmengen	61
3.1.7. Verwendung von aggregierten Informationen	61
3.2. Durchschnittliches Bestellverhalten	63
3.3. Zusammenfassung	69
4. Grundlagen der Zeitreihen- und Regressionsanalyse	71
4.1. Zeitreihenanalyse	71
4.1.1. Unterschiedliche Zeitreihenmodelle	72
4.1.2. Berechnungsverfahren	75

4.1.3.	Aktualisierung der Modelle	77
4.1.4.	Besonderheiten sporadischen Bedarfs	80
4.2.	Regressionsanalyse	81
4.3.	Autokorrelation und Heteroskedastizität	84
4.3.1.	Autokorrelation	85
4.3.2.	Heteroskedastizität	86
4.4.	Curve Fitting	87
5.	Charakterisierung des Bestellverhaltens	91
5.1.	Charakterisierung eines statischen Bestellverhaltens	92
5.1.1.	Spannweite	93
5.1.2.	Durchschnittliche Streuung	94
5.1.3.	Form der Streuung	97
5.1.4.	Korrelation	103
5.1.5.	Zusammenfassung der Kennzahlen zum statischen Bestellverhalten	108
5.2.	Charakterisierung des dynamischen Bestellverhaltens	110
5.3.	Konstanz der Bestellmengen	113
5.4.	Berechnung Kennzahlen für ausgewählte Beispiele	118
5.4.1.	Kennzahlen der Spannweite	120
5.4.2.	Kennzahlen zur Streuung	122
5.4.3.	Kennzahlen zur Korrelation	129
5.4.4.	Kennzahlen zur Konstanz der Zeitreihen	130
5.4.5.	Zusammenfassung	131
5.5.	Einsatzmöglichkeiten für Curve Fitting zur Charakterisierung des Bestell- verhaltens	132
5.6.	Zusammenfassung	137
6.	Einfluss des Bestellverhaltens auf den Entkopplungspunkt	139
6.1.	Ausgangslage und Bedeutung von ADI für den Entkopplungspunkt	139
6.2.	Erfassung der Durchlauf- und Lieferzeiten	145
6.3.	Verfahren zur ex-post Bestimmung des Entkopplungspunkts	156
6.4.	Zusammenfassung	164
7.	Analyse von Prognosemethoden mit Verwendung von Advanced Demand In- formation	166
7.1.	Wichtige Aspekte statistischer Prognosemethoden	167
7.2.	Vorstellung verschiedener Prognosemethoden	171
7.2.1.	Prognosemethoden aus der klassischen Zeitreihenanalyse	171
7.2.2.	Advanced Demand Information verwendende Prognosemethoden . .	174
7.2.2.1.	Multiplikative Prognosemethode	176
7.2.2.2.	Additive Prognosemethode	178
7.2.2.3.	Hybride Prognosemethode	179
7.2.2.4.	Übersicht weiterer Veröffentlichungen	181
7.3.	Analyse verschiedener Prognosemethoden	182

7.3.1.	Annahmen und Motivation der Analyse	182
7.3.2.	Abschätzung der Prognosegenauigkeit	186
7.4.	Einfluss des Bestellverhaltens auf die Prognosegenauigkeit	190
7.4.1.	Einfluss der Kennzahlen zur Spannweite auf die Prognosegenauigkeit	190
7.4.2.	Einfluss der Kennzahlen zur Streuung auf die Prognosegenauigkeit	191
7.4.3.	Einfluss der Kennzahlen zur Korrelation auf die Prognosegenauigkeit	193
7.4.4.	Einfluss der Kennzahlen zur Konstanz der Bestellmengen auf die Prognosegenauigkeit	194
7.5.	Zusammenfassung	195
8.	Empirische Untersuchung von Prognosemethoden	197
8.1.	Statistische Voraussetzung für eine Eignung der Methoden	197
8.1.1.	Wahl des korrekten Schätzverfahrens	198
8.1.2.	Zufällige Streuung im Bestellverhalten	203
8.1.3.	Gefahr besonders hoher Prognosefehler bei multiplikativer Methode	207
8.2.	Eignung der Prognosemethoden bei Beispieldatensätzen	209
8.2.1.	Problematik bei sporadisch vorliegenden Bestellmengen	210
8.2.2.	Problematiken bei weiteren Besonderheiten im Bestellverhalten . .	213
8.2.3.	Einsatz der Prognosemethoden beim synthetischen Datensatz . . .	217
8.3.	Zusammenfassung	218
9.	Fazit und Ausblick	220
A.	Beispielhafter Einsatz verschiedener Prognosemethoden	227
A.1.	Beispielhafter Einsatz der multiplikativen Methode	227
A.2.	Beispielhafter Einsatz der additiven Methode	231
A.3.	Beispielhafter Einsatz der hybriden Methode	235
B.	Detaillierte Ableitung der Kennzahlen zur Prognosegenauigkeit	239
B.1.	Prognosegenauigkeit der hybriden Methode	239
B.2.	Prognosegenauigkeit für Modell konstanter Nachfrage	241
B.3.	Prognosegenauigkeit für Modell einer Zeitreihe mit Trend	241
B.4.	Prognosegenauigkeit der multiplikativen Methode	245
	Literaturverzeichnis	248
	Curriculum Vitae	260

Abkürzungsverzeichnis

ADI	Advanced demand information
APS	Advanced Planning System
ATO	Assemble-to-order
DTS	Deliver-to-stock
ETO	Engineer-to-order
GM	General Motors
HP	Hierarchische Planung
LSS	Least Squares-Schätzungen
MAD	Mean absolute deviation
MAPE	Mean absolute percentage error
MLS	Maximum Likelihood-Schätzungen
MSE	Mean square error
MSTS	Make-and-ship-to-stock
MTO	Make-to-order
MTS	Make-to-stock
PMTO	Purchase-and-make-to-order\,
SKU	Stock keeping unit
VMI	Vendor Managed Inventory
VRP	Vehicle routing problem

Abbildungsverzeichnis

1.1. Supply Chain Planning-Matrix nach Rohde u.a. (2000)	2
2.1. Planungsebenen nach Anthony (1965)	8
2.2. Exemplarische Darstellung einer Planungshierarchie	11
2.3. Zweistufige Planungshierarchie nach Schneeweiss (2003, S. 17–18)	12
2.4. Exemplarische Darstellung unterschiedlicher Aggregationsebenen in zeitlicher Dimension	15
2.5. Aggregations-/Disaggregationsprozess nach Rogers u.a. (1991)	15
2.6. Beispiel für konsistente und inkonsistente Lösungen	17
2.7. Supply Chain Planning-Matrix nach Fleischmann u.a. (2008)	21
2.8. Produktionsschritte vor und nach dem Entkopplungspunkt	32
2.9. Verschiedene Entkopplungspunkte	33
2.10. Einfluss des Entkopplungspunkts auf Supply Chain Planning-Matrix nach Vogel (2014, S. 40)	38
2.11. Bestellverhalten beim klassischen Entkopplungspunktkonzept	41
2.12. Beispiel für sukzessives Bestellverhalten	42
2.13. Bestellverhalten für unterschiedliche Entkopplungspunkte nach Vollmann u.a. (1992, S. 317 ff.) und Vollmann u.a. (2005, S. 17 ff.)	43
2.14. Prozess zur Nachfrageprognose aus Kilger und Wagner (2008)	50
3.1. Zusammenhang einfache und kumulierte Bestellmengen	57
3.2. Aggregation von Bestellmengen für vorgegebenes e und s	59
3.3. Zuordnung von Tagen zu Wochen	60
3.4. Zuordnung von Wochen zu Monaten	60
3.5. ADI in Abhängigkeit von der Bestellvorlaufzeit e	64
3.6. Vergleich einzelner und durchschnittlicher Bestellwerte	67
3.7. Vergleich diskreter und kontinuierlicher Betrachtung	68
4.1. Beispiel Zeitreihe	71
4.2. Unterschiedliche Zeitreihen	72
4.3. Kombination von Trend und Saisonalität	74
4.4. Einsatz verschiedener Zeitreihenmodelle	76
4.5. Situation sporadischen Bedarfs	80
4.6. Beispiel einfache lineare Regression	82
4.7. Situationen unterschiedlicher Korrelationsstärke	84
4.8. Beispiel Autokorrelation 1. Grades	86
4.9. Beispiel Heteroskedastizität	87

4.10. Beispiel-Datensatz für das Curve Fitting	88
4.11. Einsatz des Curve Fittings beim Beispiel-Datensatz	89
5.1. Einordnung Kennzahlen zum Bestellverhalten	92
5.2. Kennzahlen zur Spannweite	93
5.3. Durchschnittsstreuung	95
5.4. Beispiel zum Zusammenhang von Streuung und Vorlaufzeit	98
5.5. Beispiele für unterschiedliche Trends	99
5.6. Exemplarische Kennzahlberechnung	110
5.7. Autokorrelation bei vorliegender Saisonalität	117
5.8. Durchschnitt und Streuung bei den kumuliert vorliegenden Bestellmengen	119
5.9. Kennzahlen zur Spannweite der Praxisdatensätze	121
5.10. Kennzahlen zur Spannweite des <i>KEKRE</i> -Datensatzes	121
5.11. Illustration der Streuungskennzahlen	124
5.12. Variationskoeffizient des <i>BUILD</i> -Datensatzes für die anteilig vorliegende Bestellmenge	125
5.13. Durchschnitt und Streuung bei verschiedenen zeitlichen Aggregationsebenen	127
5.14. Veränderung Kennzahlen auf verschiedenen zeitlichen Aggregationsebenen bei <i>BUILD</i> -Datensatz	127
5.15. Veränderung Kennzahlen auf verschiedenen zeitlichen Aggregationsebenen bei <i>CHEM</i> -Datensatz	128
5.16. An den Beispieldatensatz angepasste Normalverteilungsfunktion	132
5.17. Angepasste Funktionen für Datensätze aus Abschnitt 5.4	134
5.18. Beispielhafte Bestimmung der Spannweite für <i>FIRE</i>	135
5.19. Curve Fitting beim <i>KEKRE</i> -Beispiel für die kumuliert und einfach vorlie- gende Bestellmenge	136
6.1. Kritischer Pfad in einer Wertschöpfungskette	140
6.2. Kritischer Pfad in der Wertschöpfungskette am Beispiel eines Porzellan- herstellers	141
6.3. Einfluss der ADI auf den Entkopplungspunkt	143
6.4. Verbleibende Durchlaufzeit auf kritischem Pfad einer Wertschöpfungskette	144
6.5. Zusammenhang zwischen Rüst-, Fertigungs-, Warte- und Durchlaufzeit . .	148
6.6. Durchschnittliche Durchlaufzeiten je Rüstfamilie beim Porzellanhersteller	153
6.7. Durchschnittlich verbleibende Durchlauf- und Lieferzeit	154
6.8. Durchschnittlich verbleibende Durchlaufzeiten beim Porzellanhersteller . .	155
6.9. Planungsgrundlage in Abhängigkeit von verbleibender Lieferzeit	157
6.10. Vergleich der Vorlauf- und Lieferzeiten zur Bestimmung des Entkopplungs- punkts für blaue Tassen im Porzellanherstellerbeispiel	161
6.11. Streuung von Durchlauf- und Lieferzeiten	164
7.1. Visualisierung der Idee der zeitreihenbasierten Prognose	167
7.2. Systematische Fehleinschätzung durch Nachfrageprognose	169
7.3. Ideengrundlage unterschiedlicher ADI-basierter Prognosemethoden	174

7.4. Einfluss systematischer Fehleinschätzungen bzw. Veränderungen auf die Prognosegenauigkeit	185
8.1. Beispiel: Konstanz der anteilig vorliegenden Bestellmenge	198
8.2. Beispiel: Konstanz der ausstehenden Bestellmenge	199
8.3. Beispiel: Anteilig vorliegende Bestellmenge mit Trend	200
8.4. Beispiel: Ausstehende Bestellmenge mit Trend	202
8.5. Beispiel: Konstante Nachfrage mit konstantem Bestellverhalten	204
8.6. Beispiel: Trend in Nachfrage und Bestellverhalten	206
8.7. Skalierungseinfluss bei multiplikativer Methode	208
8.8. Anteil Wunschliefzeitpunkte mit vorliegender Bestellmenge und Prognosefehler beim <i>CHEM</i> -Datensatz für unterschiedliche Vorlaufzeiten	211
8.9. Prognosefehler beim Einsatz unterschiedlicher Schätzverfahren bei <i>FIRE</i>	214
8.10. Heteroskedastizität bei <i>BUILD</i> -Datensatz	216

Tabellenverzeichnis

2.1. Zeithorizont und Detailgrad verschiedener Planungsebenen	9
2.2. Anwendungsbeispiel für das Auftragsprofil von Meyr (2003)	44
2.3. Durchschnittliches Bestellverhalten in dem Anwendungsbeispiel aus Ta- belle 2.2	45
3.1. Bestellmengen bei unterschiedlichen Maßeinheiten	61
3.2. Berechnung arithmetisches Mittel und Standardabweichung für einfache Bestellmenge	65
3.3. Berechnung arithmetisches Mittel und Standardabweichung für kumuliert vorliegende Bestellmenge	66
3.4. Berechnung arithmetisches Mittel und Standardabweichung für ausstehen- de Bestellmenge	66
3.5. Berechnung arithmetisches Mittel und Standardabweichung für anteilig vorliegende Bestellmenge (in %)	66
3.6. Variationskoeffizienten für Beispieldaten aus Tabelle 3.2 bis 3.5 (in %) . .	68
4.1. Beispiel exponentieller Glättung für arithmetisches Mittel	78
4.2. Beispiel exponentieller Glättung für Varianz	79
4.3. Beispiel exponentieller Glättung für Kovarianz	79
4.4. Beispiel Regressionsanalyse	83
5.1. Berechnung Durchschnittsstreuung	96
5.2. Berechnung Durchschnittsvariationskoeffizient	97
5.3. Datengrundlage der Formbewertung	98
5.4. Kennzahlen zur Bewertung der Form der Streuung	101
5.5. Berechnung Kennzahlen zur Form der Streuung	102
5.6. Beispiel Student-t-Test: Zufällige Abweichungen	103
5.7. Beispiel Korrelationskoeffizient	104
5.8. Beispiel Kennzahlberechnung für durchschnittlichen Korrelations- koeffizienten	106
5.9. Beispiel Kennzahlberechnung für Trend bei Korrelationskoeffizienten . . .	107
5.10. Student-t-Test für Formkennzahl	107
5.11. Kennzahlenrahmenwerk	109
5.12. Überblick Kennzahlen des dynamischen Bestellverhaltens	112
5.13. Beispiel zur Berechnung von dynamischen Kennzahlen	113
5.14. Beispiel zur Konstanz der Zeitreihen im verallgemeinerten Auftragsprofil .	114
5.15. Beispiel Anteil konstanter Zeitreihen	116

5.16. Kennzahlen zur Spannweite für ein dynamisches Bestellverhalten	122
5.17. Durchschnittsstreuung der Datensätze	123
5.18. Streuungsform der Datensätze	123
5.19. Kennzahlen zur Streuung für ein dynamisches Bestellverhalten	126
5.20. Korrelationskennzahlen der Datensätze	129
5.21. Kennzahlen zur Korrelation für ein dynamisches Bestellverhalten	130
5.22. Kennzahlen zur Konstanz der Zeitreihen in den Datensätzen	130
5.23. Kennzahlen zur Konstanz für ein dynamisches Bestellverhalten	131
5.24. Angepasste Parameter der Funktionen aus Abbildung 5.17	133
5.25. Vergleich der durchschnittlichen Streuung aus Abschnitt 5.1.2 und der Quadratwurzel des MSE zur angepassten Funktion	134
5.26. Anteilig vorliegende Bestellmengen zu unterschiedlichen Vorlaufzeiten . . .	136
6.1. Exemplarisch gemessene Durchlaufzeiten für den zweiten Wertschöpfungs- schritt beim Porzellanhersteller (Erstellung Rohling & 1. Brand)	150
6.2. Exemplarisch gemessene Durchlaufzeiten für den dritten Wertschöpfungs- schritt beim Porzellanhersteller (Glasur & 2. Brand)	151
6.3. Exemplarisch gemessene Durchlaufzeiten für den vierten Wertschöpfungs- schritt beim Porzellanhersteller (Farbdekor & 3. Brand)	152
6.4. Bestellmenge blauer Tassen im Beispiel des Porzellanherstellers	159
6.5. Anteilig vorliegende Bestellmenge blauer Tassen im Porzellanhersteller- beispiel (in %)	159
6.6. Durchschnittlich anteilig vorliegende Bestellmenge blauer Tassen im Porzellan- herstellerbeispiel (in %)	159
6.7. Durchschnittlich anteilig vorliegende Bestellmenge grüner & gelber Tassen, roter Teller und schwarzer Schüsseln im Porzellanherstellerbeispiel (in %) .	160
7.1. Beispielhafte Nutzung der Prognosemethoden aus der klassischen Zeitrei- henanalyse	173
7.2. Prognosefehler aus beispielhafter Verwendung der Prognosemethoden . . .	173
7.3. Zusammenhang MSE, MAD und MAPE und Kennzahlen	189
7.4. Relevante Streuungskennzahlen für ADI-basierte Methoden	192
8.1. Testergebnisse zur Eignung der Kennzahlen	205
8.2. Anteil Zeitreihen im für die Prognosen relevanten Vorlaufzeitrahmen mit Trend	213
8.3. Standardmaße der Prognosefehler bei <i>FIRE</i>	215
8.4. Standardmaße der Prognosefehler bei <i>BUILD</i>	216
8.5. Prognoseungenauigkeit beim Datensatz von <i>KEKRE</i>	218
A.1. Anteilig vorliegende Bestellmengen X_{Aes} zu Beispiel aus Tabelle 5.13 (in %)227	
A.2. Anteilig vorliegende Bestellmengen x_{Aes} zu Beispiel aus Tabelle 5.13 (in %) 228	
A.3. Schätzer für verschiedene Varianten der multiplikativen Methode (in %) . 229	
A.4. Prognosen für unterschiedliche Varianten der multiplikativen Methode . . 230	
A.5. Prognosefehler für unterschiedliche Varianten der multiplikativen Methode 230	

A.6. Standardmaße zur Prognoseungenauigkeit für unterschiedliche Varianten der multiplikativen Methode	231
A.7. Ausstehende Bestellmengen U_{Aes} zu Beispiel aus Tabelle 5.13	231
A.8. Ausstehende Bestellmengen U_{Aes}^* zu Beispiel aus Tabelle 5.13	232
A.9. Schätzer für verschiedene Varianten der additiven Methode	232
A.10. Prognosen für unterschiedliche Varianten der additiven Methode	233
A.11. Prognosefehler für unterschiedliche Varianten der additiven Methode . . .	234
A.12. Standardmaße zur Prognoseungenauigkeit für unterschiedliche Varianten der additiven Methode	235
A.13. Absolute Veränderung der kumuliert vorliegenden Bestellmengen zu Bei- spiel aus Tabelle 5.13	235
A.14. Relative Veränderung der kumuliert vorliegenden Bestellmengen zu Bei- spiel aus Tabelle 5.13	236
A.15. Schätzer und Prognosen für unterschiedliche Varianten der hybriden Me- thode	236
A.16. Prognosefehler für unterschiedliche Varianten der hybriden Methode . . .	238

1. Einleitung

Prognosen sind ein essentieller Bestandteil des Wirtschaftslebens. Sie bilden die Basis für zukunftsorientierte Planungsaufgaben und deren zielorientierte Ausrichtung. Dabei sind Prognosen in den unterschiedlichsten Bereichen notwendig. Für die Beantwortung volkswirtschaftlicher Fragestellungen sind beispielsweise Konjunkturprognosen besonders relevant. Sie sind die Grundlage für finanzpolitische Entscheidungen, um auf eine veränderte Konjunkturentwicklung reagieren zu können.¹

Prognosen sind auch für betriebswirtschaftliche Themen innerhalb einer Supply Chain von großer Bedeutung. Insbesondere die Prognose der zukünftigen Nachfrage ist für Supply Chains wichtig: Ein Automobilhersteller benötigt Informationen zum erwarteten Absatz der verschiedenen Fahrzeugtypen, eine Brauerei muss über die zukünftig erwarteten Absatzvolumina ihrer verschiedenen Biermarken informiert sein, und ein Versandhandelsunternehmen braucht eine Abschätzung des erwarteten Umsatzes eines neu angebotenen Artikels. Die Nachfrageprognose kann dabei Bedeutung für die verschiedensten Planungsaufgaben einer Supply Chain haben. Sie kann Einfluss auf die Rohstoffbestellmengen im Einkauf, auf die Reihenfolge in der Produktionsplanung, auf Neueinstellungen in der Personalplanung oder die Bestandshaltung in regionalen Lagerhäusern haben. Wie stark der Einfluss auf die verschiedenen Planungsaufgaben ist, hängt von der jeweiligen Supply Chain ab. Die in Abbildung 1.1 aufgeführte Supply Chain Planning-Matrix von Rohde u.a. (2000) präsentiert und strukturiert die wichtigsten Planungsaufgaben einer Supply Chain. Die Prognose der zukünftigen Nachfrage ist die wesentliche Aufgabe des hier aufgeführten Demand Plannings.

Die große Bedeutung der Nachfrageprognose für eine Supply Chain wird bei der Untersuchung möglicher Konsequenzen ungenauer bzw. fehlerhafter Vorhersagen deutlich. So hatte beispielsweise eine Überschätzung der Nachfrage erhebliche Konsequenzen für General Motors (GM) und seine Mitarbeiter, wie der folgende Auszug aus einem Handelsblatt-Artikel verdeutlicht:

“Der Opel-Mutterkonzern bleibt auf den teuren Elektroautos Volt und Ampera sitzen - und stoppt für fünf Wochen die Produktion. Der überproduzierte Bestand reicht noch Monate. (...)

1300 Mitarbeiter sind betroffen. Der Chevrolet Volt wird fast baugleich in Deutschland auch als Opel Ampera verkauft. (...)

Opel hat sich vorgenommen, 10.000 der Wagen in diesem Jahr zu verkau-

¹Das Bundesministerium für Finanzen überwacht und untersucht entsprechend diese Entwicklung fortwährend und veröffentlicht seine Beobachtungen regelmäßig. Vgl. dazu bspw. Bundesministerium der Finanzen (2013). Die Ergebnisse dieser Prognosen und Analysen können Grundlage für weitreichende Entscheidungen in der Bundesrepublik Deutschland sein.




Abbildung 1.1.: Supply Chain Planning-Matrix nach Rohde u.a. (2000)

fen. Zuletzt lagen für den Ampera 6000 Bestellungen vor. In den Vereinigten Staaten war GM vom Chevrolet Volt im vergangenen Jahr knapp 7700 Stück losgeworden - geplant waren 10.000. In diesem Jahr wollte GM ursprünglich 60.000 Fahrzeuge produzieren, 45.000 davon alleine für den Heimatmarkt. Doch der Konzern wurde im Januar und Februar in den USA zusammen gerade mal 1600 Volt los.“

(Siehe Handelsblatt (2012))

Eine massive Überschätzung der Nachfrage resultierte bei GM in riesigen Lagerbeständen und machte einen mehrwöchigen Produktionsstopp notwendig. Neben den Implikationen für den Konzern waren auch über 1000 Mitarbeiter von dem Produktionsstopp betroffen. Das Beispiel zeigt deutlich, welche Probleme für eine Supply Chain aus ungenauen Prognosen resultieren können. Umgekehrt kann eine Unterschätzung der Nachfrage ebenfalls erhebliche Implikationen für eine Supply Chain haben. Ein weiterer Artikel aus dem Handelsblatt zeigt mögliche Konsequenzen auf:

“Volkswagen kommt wegen des Nachfragebooms mit der Produktion nicht mehr nach. Aufgrund von Engpässen bei Lieferanten musste Europas größter Autobauer am Montag die Bänder in seinem Werk in Wolfsburg anhalten. Einige Lieferanten seien nicht in der Lage, das an der Kapazitätsgrenze produzierende Stammwerk ausreichend mit Teilen zu versorgen, sagte ein Sprecher heute. (...)

Volkswagen profitiert derzeit vom Absatzboom in China und den USA. Im vergangenen Jahr lieferte der Konzern weltweit erstmals mehr als sieben Millionen Fahrzeuge aus.“

(Siehe Handelsblatt (2011))

Die Zulieferer von Volkswagen haben in diesem Fall die anhaltend hohe Nachfrage unterschätzt. Das Resultat war ebenfalls der Produktionsstopp eines Werks. Obwohl also Volkswagen Absatzrekorde erzielen kann, ist ein mögliches Optimum nicht erreicht worden. Durch den Stillstand des Stammwerks entstehen Opportunitätskosten für das gesamte Unternehmen, das nun weniger Autos herstellen und absetzen kann. Resultiert der Produktionsstopp gleichzeitig in längeren Lieferzeiten für vorliegende Bestellungen, kann eine sinkende Kundenzufriedenheit eine weitere Konsequenz sein.

Die beiden Beispiele verdeutlichen die hohe Relevanz möglichst präziser Nachfrageprognosen. Größere Abweichungen der Vorhersagen von der tatsächlichen Nachfrage haben einen negativen Einfluss auf die Planung und den Erfolg einer Supply Chain. Verfahren und Methoden, die genaue Nachfrageprognosen ermöglichen, sind deshalb von großer Bedeutung für eine Supply Chain. Eine Vielzahl statistischer Prognosemethoden ist entwickelt worden, um möglichst genaue Vorherzusagen zu erstellen. Elias u.a. (2006) präsentieren einen Überblick verschiedener solcher Methoden.

Einige neue Prognosemethoden verwenden die Informationen aus den bereits vorliegenden Bestellungen, die auch als *advanced demand information* (ADI) bezeichnet werden, für die Vorhersage der zukünftigen Nachfrage. Die bekannten konventionellen Prognosemethoden aus der Zeitreihenanalyse berücksichtigen nur die ex-post vorliegenden tatsächlichen Gesamtnachfragewerte in der Erstellung der Vorhersagen. Beispiele für solche ADI-basierte Methoden finden sich in den Arbeiten von Bestwick (1975), Kekre u.a. (1990) oder Guerrero und Elizondo (1997). Unterschieden werden dabei drei wesentliche Arten von ADI-Methoden:

1. Multiplikative Methoden,
2. Additive Methoden und
3. Hybride Methoden.

Die drei Methoden verfolgen unterschiedliche Ansätze, um die zukünftige Nachfrage zu prognostizieren. So versucht die multiplikative Methode beispielsweise, den Anteil abzuschätzen, den die bereits vorliegende Bestellmenge an der zukünftigen Nachfrage ausmacht. Durch die Skalierung der vorliegenden Bestellmenge wird anschließend die Nachfrageprognose ermittelt. Die additive Methode ist hingegen darauf konzentriert, die Bestellmenge vorherzusagen, die in der verbleibenden Zeit bis zum Wunschlieferzeitpunkt noch eingehen wird, um danach durch die Addition zu der vorliegenden Bestellmenge eine Nachfrageprognose zu erstellen. Die hybride Methode verwendet ein lineares Regressionsmodell, um auf Grundlage der vorliegenden Bestellmenge die zukünftige Nachfrage zu prognostizieren. Es existieren zahlreiche Varianten dieser Methoden, die zum Beispiel unterschiedliche Schätzverfahren für die Bestimmung der jeweiligen Schätzwerte benutzen.

Haberleitner u.a. (2010) haben die ADI-basierten Methoden in einem Unternehmen, das feuerfeste Materialien herstellt, eingesetzt und getestet. Die Güte der hier mit diesen Methoden erzeugten Prognosen ist teilweise sehr vielversprechend. Sie sind in einigen Situationen deutlich präziser als Vorhersagen, die mit konventionellen Methoden erstellt

wurden. Insbesondere bei plötzlichen Veränderungen in der Nachfrage sind die Methoden oft besser geeignet als konventionelle Methoden. Dadurch, dass die Nachfrageveränderung meistens frühzeitig in den eingehenden Bestellmengen reflektiert wird, erkennen die ADI-basierten Methoden die Veränderung eher als konventionelle Methoden, die für die Vorhersage nur die vergangenen Gesamtnachfragewerte betrachten. So wurde bei Haberleitner u.a. (2010) ein Umsatzeinbruch Anfang 2009 durch die ADI-basierten Methoden früher erkannt als durch die konventionellen Verfahren. Die Supply Chain kann sich dann entsprechend eher auf die veränderte Nachfragesituation einstellen. Kekre u.a. (1990) haben in ihrer Simulation plötzlicher Nachfrageveränderungen ähnliche Effekte beobachtet. Ein abrupter Umsatzzuwachs wurde früher als von konventionellen Methoden identifiziert und in der Prognose berücksichtigt. Auch der Einsatz der ADI-basierten Methoden zur Prognose des Personalbedarfs bei IBM in Indien durch Lee und Connors (2006) führte zu präziseren Vorhersagen als die Verwendung von konventionellen Methoden. Der Einsatz ADI-basierter Methoden kann für Supply Chains also durchaus attraktiv sein.

Wie die Arbeit von Haberleitner u.a. (2010) allerdings auch zeigt, sind die Prognosen der ADI-Methoden nicht immer präziser als die Vorhersagen konventioneller Methoden. Teilweise sind sie sogar schlechter als die konventionell erstellten Vorhersagen. Hieraus resultiert die Fragestellung: In welchen Situationen ist der Einsatz der ADI-basierten Prognosemethoden geeignet und in welchen nicht? Gibt es bestimmte Voraussetzungen, die erfüllt sein sollten, damit die ADI-basierten Prognosemethoden präzisere Vorhersagen liefern? Diese Fragen stellen sich besonders vor dem Hintergrund, dass bisher keine fertigen und leicht integrierbaren Softwaremodule existieren, die die Funktionen der ADI-basierten Methoden für ein *Advanced Planning System* (APS)² bereitstellen. Wie von Haberleitner u.a. (2010) dargestellt, muss eine Supply Chain, die die ADI-basierte Methoden einsetzen will, deren Implementierung im APS entsprechend eigenständig planen und durchführen. Offensichtlich will eine Supply Chain den damit verbundenen Aufwand genau dann auf sich nehmen, wenn die durch die ADI-basierten Methoden erstellten Prognosen deutlich besser als die bisherigen konventionell erzeugten Vorhersagen sind. Es ist deshalb das Ziel dieser Arbeit, Supply Chains bei der Identifikation von Situationen zu unterstützen, in denen der Einsatz ADI-basierter Prognosemethoden geeignet ist. Dazu werden die Voraussetzungen für die Erzeugung präziser Vorhersagen durch die ADI-basierten Methoden ermittelt und herausgearbeitet. Eine Supply Chain kann sie als Indikatoren nutzen, um eine fundierte Entscheidung zur Implementierung dieser Prognosemethoden zu treffen. Dies war bisher nicht möglich.

Die folgende Analyse ist in sieben Kapitel unterteilt. In Kapitel 2 wird zunächst die untersuchte Fragestellung dieser Arbeit in einen Gesamtkontext zu den verschiedenen Aufgaben des Supply Chain Managements gestellt und entsprechend eingeordnet. Grundlage für diese Darstellung bildet die bereits in Abbildung 1.1 aufgeführte Supply Chain Planning-Matrix. Für die Untersuchung der ADI-basierten Prognosemethoden ist es dann zunächst notwendig, die ADI strukturiert zu erfassen und analysieren. Dies ist der Schwer-

²Stadtler (2008d) definiert ein APS als ein Softwareprodukt, das eine Supply Chain bei der Bearbeitung der verschiedenen in der Supply Chain Planning-Matrix aufgeführten Planungsaufgaben unterstützt. Dies kann auch die Vorhersage der zukünftigen Nachfrage umfassen. Die Struktur und der Aufbau eines APS werden unter anderem von Meyr u.a. (2008b) erklärt.

punkt der Kapitel 3 bis 5. In Kapitel 3 werden die notwendigen Variablen definiert, um die ADI formal zu erfassen und abzubilden. Sie dienen als Grundlage für die gesamte Arbeit. In Kapitel 4 werden anschließend die statistischen Grundlagen aus der Zeitreihen- und Regressionsanalyse für die nachfolgenden Untersuchungen vorgestellt. In diesem Zusammenhang wird auch das Curve Fitting-Verfahren erläutert, das zur Charakterisierung des Bestellverhaltens ebenfalls eingesetzt werden kann. In Kapitel 5 werden dann Kennzahlen identifiziert, die eine kompakte Einschätzung wesentlicher Aspekte des Bestellverhaltens ermöglichen, das mit der ADI verbunden ist. Die Kennzahlen erlauben es in einer übersichtlichen Darstellung, das Bestellverhalten zu charakterisieren und beurteilen.

Da die ADI nicht ausschließlich zur Prognose zukünftiger Nachfrage eingesetzt werden kann, sind die in Kapitel 5 eingeführten Kennzahlen gegebenenfalls auch für andere Planungsaufgaben relevant. Exemplarisch wird dafür in Kapitel 6 der Einfluss des Bestellverhaltens auf das Entkopplungspunktkonzept³ analysiert. Die Analyse zeigt den engen Zusammenhang zwischen Kundenaufträgen und dem Entkopplungspunkt auf. Sie ermöglicht so eine fundierte ex-post Untersuchung und Beurteilung des Entkopplungspunkts. Eine ex-post Bestimmung des tatsächlich verwendeten Entkopplungspunkts wird so erstmals ermöglicht und ist gleichzeitig eine wertvolle Grundlage für die Identifikation von Optimierungspotenzialen. Die bisher teilweise mangelnde Quantifizierung einer Entkopplungspunktanalyse wird so behoben.

Die Analyse der ADI-basierten Prognosemethoden wird anschließend in Kapitel 7 und 8 vorgenommen. Dabei werden die Methoden in Kapitel 7 zunächst analytisch untersucht. Hier werden auch die Kennzahlen entwickelt, die es einer Supply Chain erlauben, die Genauigkeit ADI-basierter und konventioneller Prognosemethoden abzuschätzen und zu vergleichen. Diese Kennzahlen werden es zukünftig einer Supply Chain ermöglichen, eine fundierte Entscheidung zum Einsatz und der Implementierung ADI-basierter Methoden zu treffen. Die entwickelten Kennzahlen resultieren aus einer ex-post Analyse der ADI. Um die Präzision von Prognosemethoden abzuschätzen, ist ein häufig benutztes alternatives Verfahren, deren Verwendung mit historischen Werten zu simulieren und die Abweichung von den bekannten tatsächlichen Werten zu messen. Für dieses Vorgehen wird allerdings eine Implementierung der Methode benötigt, die im Fall der ADI-basierten Methoden eben nicht in einem APS vorhanden ist. Die Supply Chain kann die ADI-basierten Methoden für die Simulation natürlich außerhalb des APS beispielsweise in einem Tabellenkalkulationsprogramm implementieren. Hierfür ist allerdings ein genaues Verständnis dieser Methoden notwendig, das aber in vielen Supply Chains nicht vorhanden ist. Die in dieser Arbeit entwickelten Kennzahlen sind einfacher zu berechnen und ermöglichen so eine Genauigkeitsabschätzung der ADI-basierten Prognosemethoden. Eine Supply Chain kann sich also für eine aufwendige Implementierung im APS entscheiden, wenn die durch die ADI-basierten Methoden erstellten Prognosen die Vorhersagegenauigkeit auch signifikant verbessern. Im anschließenden Kapitel 8 werden sowohl die verschiedenen Methoden als auch die Kennzahlen empirisch untersucht. Für diese Untersuchung wurden mehrere Praxisdatensätze sowie synthetisch erzeugte Werte verwendet.

³Eine umfassende Erläuterung und Einordnung des Entkopplungspunktkonzepts erfolgt in den Kapiteln 2 und 6.

Die Lektüre der folgenden Arbeit wird dem interessierten Leser einen Einblick in die Struktur und Einsetzbarkeit der ADI geben. Die beispielhafte Zusammenführung mit dem Entkopplungspunktkonzept wird ihm dabei zeigen, welche integrale Rolle die ADI in den Planungsaufgaben einer Supply Chain spielt und welchen großen Mehrwert sie schaffen kann. Die verschiedenen Varianten ADI-basierter Prognosemethoden werden umfassend erläutert, und durch das Kennzahlenwerk wird deren Nutzen für den potentiellen Anwender vor einer Implementierung erstmals quantitativ abschätzbar.

2. Grundlagen des Supply Chain Managements

Im letzten Kapitel wurde die Motivation für diese Arbeit dargelegt. Ziel dieses Kapitels ist es, die untersuchten Fragestellungen in einen Gesamtkontext zum Supply Chain Management und den diversen damit verbundenen Aufgaben zu stellen. Dem Leser soll so ein Eindruck von der Relevanz der Fragestellungen und deren Einfluss auf andere Aufgaben des Supply Chain Managements vermittelt werden. Es soll ihm dadurch ermöglicht werden, die Bedeutung der Ergebnisse dieser Arbeit für eine Supply Chain besser abschätzen zu können.

Hierfür wird zunächst in Abschnitt 2.1 der Begriff *Supply Chain Management* allgemein definiert. Es wird zudem die Supply Chain Planning-Matrix vorgestellt, die sich zur Strukturierung der verschiedenen Aufgaben in diesem Rahmen eignet. Die unterschiedlichen Planungsmodule dieser Matrix werden direkt danach in Abschnitt 2.2 beschrieben, um dem Leser einen Gesamteindruck von den Planungsaufgaben im Supply Chain Management und ihren Interdependenzen zu vermitteln.

In den darauffolgenden Abschnitten werden die Fragestellungen dieser Arbeit in der Struktur der Supply Chain Planning-Matrix positioniert und abgegrenzt. Dafür wird in Abschnitt 2.3 das Entkopplungspunktkonzept erst umfassend erklärt und dann in Abschnitt 2.4 dessen Bedeutung für die verschiedenen Planungsmodule der Supply Chain Planning-Matrix erläutert. Analog wird die Relevanz ADI-basierter Prognosemethoden für die Planungsmodule in Abschnitt 2.5 dargelegt.

2.1. Supply Chain Management

In der Literatur finden sich zahlreiche Definitionen des Begriffs *Supply Chain Management*. In dieser Arbeit wird die Definition verwendet, die bereits von Lambert u.a. (1998) in dieser Form vorgestellt wurde:

“Supply chain management is the integration of key business processes from end user through original suppliers that provides products, services, and information that add value for customers and other stakeholders.”

Aufgabe des Supply Chain Managements ist nach dieser Definition die Integration der wichtigsten Geschäftsprozesse. Es sollen dabei Waren für einen Kunden bereitgestellt werden, wobei es sich um physische Produkte, Dienstleistungen oder auch Informationen handeln kann. Die Integration bezieht sich auf die gesamte Prozesskette vom ersten Lieferanten bis zum Endverbraucher.

Die Geschäftsprozesse sind zunächst nicht automatisch aufeinander abgestimmt und integriert. Um dies zu gewährleisten, sind diverse Planungsaufgaben im Rahmen des Supply Chain Managements zu bearbeiten. Diese Planungsaufgaben haben wiederum verschiedene Merkmale und Zielsetzungen. Sie stehen aber gleichzeitig auch in Beziehung zueinander, so dass die Ergebnisse einer Planungsaufgabe großen Einfluss auf eine andere Aufgabe haben können. In diesem Abschnitt werden nun verschiedene Ansätze erläutert, die es ermöglichen, diese Planungsaufgaben zu strukturieren und koordinieren.

Bereits von Anthony (1965) wurde festgestellt, dass in einer Supply Chain meist mehrere Planungsebenen existieren. Er unterscheidet dabei eine strategische, eine Management- und eine operative Ebene.¹ Auf der strategischen Ebene wird über die langfristige Ausrichtung sowie die Zielsetzungen der Supply Chain entschieden. Die Bereitstellung der notwendigen Ressourcen, um diese Ziele zu erreichen, wird auf der Management-Ebene geplant. Auf der operativen Ebene muss nach Anthony (1965) dann sichergestellt werden, dass die vorhandenen Ressourcen *„effektiv und effizient“* zur Erreichung der Unternehmensziele eingesetzt werden. Die Ebenen stehen dabei in direktem Bezug zueinander. Wie von Anthony (1965) beschrieben, ist die auf der strategischen Ebene bestimmte Zielsetzung die Grundlage für die weitere Planung auf den beiden anderen Ebenen. Auf der operativen Ebene muss der Einsatz der Ressourcen geplant werden, die als Resultat der Planung auf der Management-Ebene zur Verfügung stehen. Abbildung 2.1 illustriert diesen Zusammenhang.




Abbildung 2.1.: Planungsebenen nach Anthony (1965)

Wie unter anderem von Fleischmann u.a. (2008) dargestellt, sind mit den verschiedenen Planungsaufgaben unterschiedliche Zeithorizonte verbunden. So wird auf der strategischen Ebene meist langfristig, auf der Management-Ebene mittelfristig und auf der operativen Ebene kurzfristig geplant. Der Detailgrad der Planung steigt dabei mit abnehmenden Zeithorizont. So werden auf der operativen Ebene Planungsaufgaben gelöst, die in detaillierte und konkrete Arbeitsanweisungen münden, wie Fleischmann u.a. (2008)

¹Wie von Fleischmann u.a. (2008) hervorgehoben, wird die Management Planungsebene in der Literatur auch häufig als taktische Ebene bezeichnet. Schneck (2007, S. 881–882) benutzt diesen Begriff beispielsweise, Anthony (1965) verwendet ihn allerdings nicht.

beschreiben. Das Ergebnis einer solchen Aufgabe kann beispielsweise ein Maschinenbelegungsplan sein, der genau angibt, welches Produkt mit welcher Spezifikation auf welchem Gerät zu welchem Zeitpunkt zu fertigen ist. Mit einem mittelfristigen Zeithorizont wird hingegen nur geplant, wieviel Maschinenkapazität für die Produktion der verschiedenen Produktfamilien in den kommenden Monaten ungefähr bereitsteht. Dabei enthält eine Produktfamilie mehrere Produkte mit unterschiedlichen Spezifikationen. Genaue Zeitangaben oder Produktspezifikationen sind also nicht Teil dieser Planung. In der langfristigen strategischen Planung wird bestimmt, welche Standorte für die Produktion der verschiedenen Produktfamilien verwendet werden bzw. dafür aufzubauen sind. Häufig wird in dieser Planung nur noch die durchschnittliche Produktionsmenge je Standort und Produktfamilie berücksichtigt. Eine genaue zeitliche Zuordnung oder eine Betrachtung konkreter Produktspezifikationen findet dabei üblicherweise nicht statt. Entsprechend der Struktur von Anthony (1965) ist die langfristige strategische Standortplanung gleichzeitig eine wichtige Grundlage jeglicher mittelfristigen Ausarbeitung von Maschinenkapazitäten oder der Entwicklung von kurzfristigen operativen Maschinenbelegungsplänen. Tabelle 2.1 enthält eine Übersicht der mit den verschiedenen Planungsebenen verbundenen Zeithorizonte und Detailgrade.

Planungsebene nach Anthony (1965)	Zeithorizont	Detailgrad
Strategisch	langfristig	niedrig
Management	mittelfristig	mittel
Operativ	kurzfristig	hoch

Tabelle 2.1.: Zeithorizont und Detailgrad verschiedener Planungsebenen

Zwei weitere Unterschiede zwischen den Planungsebenen wurden von Hax und Golovin (1978) identifiziert. Dies sind zum einen die für eine Planungsaufgabe verantwortliche Managementebene und zum anderen das mit einer Entscheidung verbundene Risiko. So liegt die Verantwortlichkeit für die im Rahmen der Planung getroffenen Entscheidungen auf unterschiedlichen Managementebenen in einer Supply Chain. Strategische Entscheidungen mit einem langfristigen Einfluss auf die Supply Chain werden üblicherweise von deren Top-Management getroffen. Mit abnehmendem Zeithorizont und steigendem Detailgrad ist es meistens gleichzeitig eine niedrigere Managementebene, die für die Planungsaufgabe verantwortlich ist. Die operative Planung wird vom unteren Management durchgeführt. Gleichzeitig ist zu beachten, dass sich mit der Länge des Zeithorizonts, auf den sich die Planung bezieht, das damit verbundene Risiko erhöht. Ein schlechter Maschinenbelegungsplan für die nächste Woche wird nicht den gleichen negativen Effekt auf die Supply Chain haben wie die suboptimale Bestimmung neuer Produktionsstandorte. Inhaltlich eng verbunden mit dieser Differenzierung der Planungsaufgaben ist das Konzept der *hierarchischen Planung* (HP). Es wurde von Hax und Meal (1975) vorgestellt und unter anderem in den Veröffentlichungen von Hax und Golovin (1978), Bitran und Hax (1977), Bitran u.a. (1981, 1982), Stadtler (1986), Schneeweiss (2003, S. 159–204), Stadtler und Fleischmann (2012) sowie Vogel (2014) aufgegriffen. Die folgenden Ausführungen zur HP in Abschnitt 2.1.1 basieren auf diesen Arbeiten. Die Supply Chain

Planning-Matrix wird anschließend in Abschnitt 2.1.2 beschrieben.

2.1.1. Hierarchische Planung

Für die Entwicklung der HP gab es mehrere Gründe. Es wurde ein Planungskonzept benötigt, das zum einen die Unterschiede zwischen den Planungsaufgaben auf den verschiedenen Ebenen berücksichtigt, gleichzeitig aber auch deren Abhängigkeiten und Interdependenzen beachtet. Bereits Hax und Meal (1975) haben festgestellt, dass ein monolithischer Ansatz, der sämtliche Planungsaufgaben als zusammenhängend betrachtet und entsprechend gleichzeitig löst, weder praktikabel noch umsetzbar ist. Ein solcher Ansatz würde vom Management der Supply Chain in den meisten Fällen nicht akzeptiert werden, da er den Entscheidungsprozess erschweren und eine Ausgestaltung entsprechend den Verantwortlichkeiten verhindern würde. Zusätzlich würde er die Komplexität und den Aufwand der Planung unnötig erhöhen. So wäre bei jeder Veränderung der Ausgangslage die gesamte Planung neu durchzuführen. Eine Konzentration auf die davon betroffenen Planungsbereiche wäre nicht möglich.

Vor diesem Hintergrund wurde die HP entwickelt. Sie kann durch die folgenden fünf Grundprinzipien charakterisiert werden, die von Stadtler und Fleischmann (2012) unterschieden werden:

1. Problemzerlegung und der Aufbau einer hierarchischen Struktur
2. Koordination zwischen verschiedenen Planungsaufgaben
3. Betrachtung unterschiedlicher Aggregationsebenen
4. Modellierung von Planungsaufgaben
5. Lösung bzw. Optimierung der erstellten Modelle

Das Konzept der HP wird nun entlang dieser fünf Grundprinzipien erläutert.

Problemzerlegung und der Aufbau einer hierarchischen Struktur

Da ein monolithischer Planungsansatz aus den beschriebenen Gründen nicht praktikabel ist, wird die Planungsaufgabe in der HP in Teilprobleme zerlegt. Als Beispiel sei hier eine Supply Chain aus dem Vertrieb genannt, die die jährliche Planung ihres Personals in Europa durchführen möchte. Anstatt diese Planung auf europäischer Ebene detailliert auszuarbeiten, kann es für die Supply Chain einfacher sein, die Planung für jedes Land separat vorzunehmen. Die Supply Chain würde das Planungsproblem also entlang geographischer Eigenschaften in mehrere Teilprobleme zerlegen. Eine wichtige Eigenschaft der HP ist dabei die Einordnung der Teilprobleme in eine hierarchische Struktur. Das ursprüngliche Planungsproblem wird also in eine Hierarchie von Teilproblemen zerlegt. Eine wichtige Eigenschaft dieser Planungshierarchien ist dabei die eindeutige Zuordnung eines Teilproblems zu einem übergeordneten Planungsproblem. Die verschiedenen nationalen Vertriebsplanungen sind in der Hierarchie beispielsweise eindeutig unter der europäischen Planung einzuordnen. Werden die nationalen Vertriebsplanungen regional weiter zerlegt, so unterstehen die daraus resultierenden Teilplanungen der jeweiligen nationalen Planung

in der Hierarchie. Die Planung in Deutschland könnte zum Beispiel für die verschiedenen Bundesländer getrennt erfolgen; dies wäre dann der nationalen Planung für Deutschland untergeordnet.

Der Vorteil der HP ist, dass die Planungsprobleme auf den verschiedenen Hierarchieebenen einfacher den unterschiedlichen Managementebenen einer Supply Chain zugeordnet werden können. So kann in dem Beispiel der europäische Vertriebsvorstand die Verteilung der bereitstehenden Vertriebsmitarbeiter auf die verschiedenen Länder vornehmen. Die ihm untergeordneten nationalen Vertriebsleiter führen dann die detaillierte nationale Planung durch, indem sie die Mitarbeiter verschiedenen Regionen zuweisen. Ein für die Region verantwortlicher Mitarbeiter würde die ihm zugeteilten Mitarbeiter dann ihrem genauen Einsatzgebiet zuordnen. Die Zerlegung der Planungsaufgabe in eine hierarchische Struktur ist für das Vertriebsbeispiel in Abbildung 2.2 illustriert.²




Abbildung 2.2.: Exemplarische Darstellung einer Planungshierarchie

Koordination zwischen verschiedenen Planungsaufgaben

Der zweite wichtige Aspekt einer HP ist die Koordination zwischen den Planungsaufgaben auf den verschiedenen Hierarchieebenen. Eine Koordination ist notwendig, um die Beziehungen und Interdependenzen zwischen den Planungsaufgaben zu berücksichtigen. An dieser Stelle wird zur Erläuterung eine einfache, aus zwei Ebenen bestehende Hierarchie betrachtet. Sie wurde ursprünglich von Schneeweiss (2003, S. 17–18) eingeführt und ist in Abbildung 2.3 dargestellt. Die Hierarchie besteht aus einer Top- und einer eindeutig zugeordneten Basis-Ebene. Die Umsetzung der Planung erfolgt in einem Objekt-System. Das Objekt-System ist somit eine abstrakte Beschreibung der Implementierung dessen, was auf der Top- und Basis-Ebene geplant wurde. Von Schneeweiss (2003, S. 17–18)

²In diesem Beispiel wurde der deutsche Vertriebsplan exemplarisch zerlegt. Eine analoge Zerlegung der Planung ist für die anderen europäischen Länder parallel ebenso durchführbar.

werden folgende drei Formen der Koordination unterschieden, um die Interdependenzen zwischen den Ebenen zu beschreiben:

1. Top-down Instruktion
2. Bottom-up Reaktion
3. Bottom-up Antizipation

Durch die Entscheidungen auf der Top-Ebene werden die Planungsmöglichkeiten auf der Basis-Ebene beschränkt. Diese Beschränkungen werden in Form von top-down Instruktionen an die Basis-Ebene weitergegeben. Im vorherigen Vertriebsplanungsbeispiel kann beispielsweise auf europäischer Ebene entschieden werden, wieviel Personal für die verschiedenen Nationen im kommenden Jahr bereitgestellt wird. Die jeweiligen nationalen Planungen müssen diese vorgegebene Personalkapazität dann entsprechend beachten.




Abbildung 2.3.: Zweistufige Planungshierarchie nach Schneeweiss (2003, S. 17–18)

Auf die Vorgaben der Top-Ebene kann die Basis-Ebene in bestimmten Situationen durch ein Feedback reagieren. Diese Form der Koordination ist bottom-up. Die untere Ebene gibt auf eine konkrete top-down Instruktion ein Feedback zurück. In dem Vertriebsbeispiel könnte die nationale Vertriebsleitung eines Landes beispielsweise auf die vorgegebene Personalkapazität reagieren und hervorheben, dass die eingeplanten Mitarbeiter nicht genügen, um die gesetzten Umsatzziele zu erreichen. Sie würde dann in ihrem Feedback entsprechend mehr Personal fordern. Die Top-Ebene kann dann auf dieses Feedback reagieren.³

³Wie bereits erläutert, erfolgt die Umsetzung der Planung in einem Objekt-System. Für die zukünftige Planung hilfreiches Feedback aus der Umsetzung kann von dem Objekt-System ex-post an die Top- und Basis-Ebene zurückgespielt werden, wie in Abbildung 2.3 dargestellt. In dem Beispiel könnten

Als letzte Form der Koordination gibt es die bottom-up Antizipation. In diesem Fall betrachtet die Top-Ebene vor einer Entscheidung und der damit verbundenen top-down Instruktion die Charakteristika der Basis-Ebene. Sie antizipiert die auf ihre Instruktion folgende Planung auf der unteren Ebene durch eine sogenannte antizipierte Basis-Ebene und berücksichtigt das erwartete Verhalten wiederum in ihrer eigenen Planung. In dem Vertriebsbeispiel könnte dies bedeuten, dass bei der Zuteilung der Personalkapazitäten auf europäischer Ebene die nationalen Umsatzziele mit in Betracht gezogen, die resultierenden nationalen Planungen antizipiert und in der Zuordnung von Vertriebsmitarbeitern berücksichtigt werden.

Betrachtung unterschiedlicher Aggregationsebenen

Wie bereits zuvor erwähnt, sind mit verschiedenen Planungsaufgaben unterschiedliche Detailgrade verbunden. Dies gilt auch für die HP. Um unterschiedliche Detailgrade zu berücksichtigen, werden in der HP verschiedene Aggregationsebenen betrachtet. Auf einer solchen Aggregationsebene werden verschiedene planungsrelevante Objekte zusammengefasst, die dann in der Planungsaufgabe nicht mehr differenziert behandelt werden. Ein solches Objekt kann beispielsweise ein Produkt der Supply Chain mit einer eindeutigen Spezifikation sein. Eine Produktfamilie, die mehrere eindeutige Produkte umfasst, stellt dann eine Aggregationsebene da. Der Prozess zur Erstellung einer solchen Aggregationsebene wird einfach Aggregation genannt.

Für unterschiedliche Planungsaufgaben können verschiedene Aggregationsebenen verwendet werden. So ist bei der Erstellung eines kurzfristigen Maschinenbelegungsplans der genaue Zeitpunkt für die Produktion eines Produkts mit einer eindeutigen Spezifikation zu bestimmen. Wird hingegen mittelfristig die Verwendung der verfügbaren Maschinenkapazitäten geplant, dann werden eventuell nur die Produktionsmengen je Produktfamilie ermittelt. Welche Kapazitäten für die Produktion der verschiedenen Produkte innerhalb der Familie bereitstehen, wird nicht explizit eingeplant. In dieser mittelfristigen Planung wird also eine Aggregationsebene verwendet, die nicht einzelne Produkte wie bei der kurzfristigen Maschinenbelegungsplanung untersucht, sondern diese undifferenziert betrachtet und in Produktfamilien zusammenfasst.

Wie unter anderem Stadtler und Fleischmann (2012) sowie Vogel (2014) vermerken, dient die Betrachtung von Aggregationsebenen einer Komplexitätsreduktion in der Planung. Nicht notwendige Details werden durch die Verwendung von Aggregationsebenen ausgeblendet. In dem Beispiel der mittelfristigen Planung von Maschinenkapazitäten sind es die individuellen Produktspezifikationen, die durch die Nutzung von Produktfamilien nicht beachtet werden. Wie Hax und Golovin (1978) beschreiben, ist ein wesentlicher Vorteil beim Einsatz von Aggregationsebenen, dass die Verständlichkeit für die verschiedenen Management-Ebenen durch eine Fokussierung auf die relevanten Details gesteigert wird. Zusätzlich vereinfachen die Aggregationsebenen die Datenerhebung und -verarbeitung. Es erfolgt nun eine deskriptive Erläuterung von Aggregationsebenen. Eine formelle Definition der für diese Arbeit relevanten Aspekte unterschiedlicher Aggregationsebenen

die lokalen Vertriebseinheiten, in denen die Planungsergebnisse implementiert werden, ihr Feedback im Nachhinein an die nationale und europäische Vertriebsleitung geben und darin mögliche Defizite der Vertriebsplanung beschreiben.

erfolgt in Kapitel 3.

Wie bereits Stadtler und Fleischmann (2012) festgestellt haben, sind bei der Aggregation zwei wesentliche Dimensionen zu unterscheiden, nämlich eine Aggregation in der zeitlichen Dimension und eine von Objekten. Letzteres wurde bereits exemplarisch vorgestellt. Wie Stadtler und Fleischmann (2012) beschreiben, werden bei dieser Form der Aggregation Objekte mit bestimmten Eigenschaften zusammengefasst, die dann wiederum ein aggregiertes Objekt bilden. In dem vorherigen Beispiel wurden als Objekte die einzelnen Produkte der Supply Chain und deren Zugehörigkeit zu einer Produktfamilie als relevante Eigenschaft für die Aggregation verwendet. Es können aber auch andere Produkteigenschaften für die Aggregation genutzt werden. So können Produkte mit der gleichen Farbe oder bestimmten technischen Eigenschaften aggregiert werden. Es können auch andere Objekte als die Produkte einer Supply Chain für die Aggregation betrachtet werden. Exemplarisch seien an dieser Stelle die Kunden oder Maschinen einer Supply Chain als solche Objekte genannt. Plant die Supply Chain beispielsweise den erwarteten Jahresabsatz für eine bestimmte Produktfamilie, wird sie wahrscheinlich nicht versuchen, die Nachfrage jedes einzelnen Kunden zu ermitteln, sondern die Nachfrage verschiedener Kundengruppen abzuschätzen. Sie kann beispielsweise Kunden nach geographischen Aspekten zusammenfassen. Die relevante Eigenschaft für die Aggregation der Kunden wäre also deren Stand- bzw. Wohnort. Verwendet die Supply Chain eine solche Aggregationsebene, kann sie statt einzelner Kunden zum Beispiel bestimmte Regionen oder Länder für die Absatzplanung untersuchen. Die Supply Chain kann für die Aggregation auch eine Kombination von Eigenschaften verwenden. Bei der Gruppierung von Endkunden kann unter anderem noch das Alter, das Geschlecht oder das Einkommen benutzt werden. Auch die Maschinen einer Supply Chain können nach diversen Eigenschaften gruppiert und für entsprechende Planungsaufgaben zusammengefasst werden. Exemplarisch sind hier als Eigenschaften für eine Aggregation der Standort, die Produktionskapazität oder die mit der Maschine verbundenen Fertigungsschritte aufgezählt.

Wie bereits von Stadtler und Fleischmann (2012) erwähnt, kann für die Aggregation neben den planungsrelevanten Objekten auch die zeitliche Dimension verwendet werden. Die Betrachtung unterschiedlicher Aggregationsebenen in der zeitlichen Dimension wird insbesondere dann relevant, wenn eine Planung für diskrete Zeiträume vorgenommen wird.⁴ So kann die Produktionsmenge eines Gutes beispielsweise auf Tages-, Wochen- oder Monatsbasis geplant werden. Alle drei Beispiele beschreiben unterschiedliche Aggregationsebenen. Abbildung 2.4 stellt dies exemplarisch dar. Es sind die geplanten Produktionsmengen auf Tages-, Wochen- und Monatsbasis für ein fiktives Gut und ein beliebigen Monat aufgeführt, der 30 Tage hat und mit einem Montag beginnt. Die Tagesmengen variieren zwischen 8 und 10 Einheiten. Die Produktionsmenge beträgt für die vier abgebildeten Wochen jeweils 66 Einheiten. Für den gesamten Monat sind 284 Einheiten eingeplant.⁵

⁴Wird die Zeit in der Planung als kontinuierlich betrachtet, ist eine solche Aggregation nicht anwendbar, wie auch Stadtler und Fleischmann (2012) vermerken.

⁵Die Problematik, dass die Zeiträume auf den verschiedenen zeitlichen Aggregationsebenen nicht eindeutig einander zugeordnet werden können, wird in Kapitel 3 aufgegriffen. In Abbildung 2.4 ist beispielsweise die Menge für die Woche 5 nicht eindeutig dem Monat 1 zuzuteilen.

	Tag																													
Produktionsmenge	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
auf Tagesbasis	10	10	10	10	10	8	8	10	10	10	10	10	8	8	10	10	10	10	10	8	8	10	10	10	10	10	8	8	10	10
	Woche 1							Woche 2							Woche 3							Woche 4							5	
auf Wochenbasis	66							66							66							66								
	Monat 1																													
auf Monatsbasis	284																													

Abbildung 2.4.: Exemplarische Darstellung unterschiedlicher Aggregationsebenen in zeitlicher Dimension

Ein wichtiger Aspekt der Aggregation ist der damit verbundene Informationsverlust, wie ihn beispielsweise Vogel (2014, S. 31) beschreibt. Die Aggregation reduziert die Anzahl der Objekte, die in einer Planungsaufgabe zu berücksichtigen sind. Sie fasst sie zu aggregierten Objekten zusammen. Die resultierende Lösung für die Planungsaufgabe bezieht sich entsprechend auf diese aggregierten Objekte. Mit den Aufgaben auf den verschiedenen Ebenen der aufgebauten Planungshierarchie sind bei der HP verschiedene Detailgrade und Aggregationsebenen verbunden. Es ist deshalb oft notwendig, ein Ergebnis auf die ursprünglichen Objekte zurückzuführen, da eine erarbeitete Lösung auf einer höheren Ebene die Grundlage für die Detailplanung auf einer niedrigeren Ebene ist. Die aggregierten Objekte aus der Lösung sind hierfür zu disaggregieren. Die Disaggregation ist der umgekehrte Vorgang zur Aggregation. Dieser Zusammenhang ist Abbildung 2.5 illustriert, die aus einer Darstellung von Rogers u.a. (1991) abgeleitet wurde.




Abbildung 2.5.: Aggregations-/Disaggregationsprozess nach Rogers u.a. (1991)

Die Schwierigkeit bei der Disaggregation ist, dass bei den aggregierten Objekten meistens die Informationen fehlen, die es erlauben, diese wieder genau auf die ursprünglichen Objekte herunterzubrechen.⁶ Die notwendigen Informationen sind durch die Aggregation

⁶Eine Disaggregation, die diese genaue Zuordnung erlaubt, wird unter anderem von Axsäter (1986) und

verloren gegangen. Wenn die Supply Chain wie in dem Beispiel zuvor sämtliche Kunden eines Landes für die Absatzplanung aggregiert, dann beschreibt auch die resultierende Lösung die Absatzmenge für gesamte Länder. Wird nun allerdings für andere Planungsaufgaben die Absatzmenge je Kunde benötigt, dann muss die vorliegende Planungslösung disaggregiert werden. Die notwendigen Informationen, um diese Mengen genau auf die Kunden aufzuteilen, sind allerdings nach der Aggregation nicht mehr vorhanden.

Es existieren verschiedene Methoden, um eine Aggregation oder Disaggregation durchzuführen. Einige Varianten werden beispielsweise von Bitran u.a. (1981, 1982) sowie Rogers u.a. (1991) vorgestellt. Sie sind, wie die Autoren beschreiben, von der Situation abhängig, in der sie eingesetzt werden. Einige Methoden, die sich für die Aggregation von Mengen wie bei der zuvor erläuterten Absatzplanung eignen, werden von Vogel (2014, S. 112–117) dargestellt. So kann bei dem bekannten Beispiel die Absatzmenge aller bei der Aggregation zusammengefassten Kunden einfach summiert werden, um die Menge für das aggregierte Objekt zu ermitteln. Soll bei der Disaggregation die eingeplante Menge für ein gesamtes Land auf n Kunden verteilt werden, wird jedem Kunden einfach die gleiche Menge zugeordnet. Sie kann durch die Multiplikation der Gesamtmenge mit $1/n$ errechnet werden.

Wichtige Themen bei der Aggregation und Disaggregation sind die Konsistenz und Umsetzbarkeit der ermittelten Lösungen auf den verschiedenen Ebenen, die die eingesetzten Verfahren sicherstellen müssen. Konsistenz liegt genau dann vor, wenn sich die Lösungen auf den verschiedenen Ebenen nicht gegenseitig widersprechen. Bitran und Hax (1977) sowie Hax und Golovin (1978, S. 410) beschreiben exemplarisch die Bedingungen für konsistente Lösungen bei einem hierarchischen Produktionsplanungsproblem. Es sollen mit einer HP die Produktionsmengen verschiedener Produkte ermittelt werden. Dabei werden die Produkte für die HP zu Produktfamilien aggregiert. Bedingung für die Konsistenz der Lösungen ist, dass die im Rahmen der HP ermittelten Produktionsmengen einer Produktfamilie der Summe der Produktionsmengen der darin enthaltenen Produkte entsprechen. In Abbildung 2.6 sind beispielhaft konsistente und inkonsistente Lösungen dargestellt. Für die Bestimmung des Produktionsvolumens wird die gesamte Produktfamilie bestehend aus den Produkten A, B und C betrachtet. Es wird hier exemplarisch ein Produktionsvolumen von 100 Stück für die Produktfamilie ermittelt. Im linken Beispiel werden bei der Disaggregation jeweils 30% der gesamten Menge den Produkten A und C und 40% dem Produkt B zugeordnet. Die links dargestellten Produktionsmengen der einzelnen Produkte summieren sich genau zu dem Volumen der Produktfamilie. Die Lösungen sind konsistent. Im rechten Beispiel wurde der Disaggregation die Annahme zugrunde gelegt, dass das Volumen von Produkt B dem von Produkt A entspricht, während von Produkt C 10 Stück weniger hergestellt werden. Das Volumen von Produkt A wurde auf Basis von vergangenen Produktionsmengen mit 40 Stück abgeschätzt. Im rechten Beispiel addieren sich die Produktionsmengen der einzelnen Produkte so zu 110 Stück. Die Lösungen sind entsprechend inkonsistent.

Die folgenden Ausführungen zur Umsetzbarkeit basieren auf den Erläuterungen von Ax-

Vogel (2014, S. 30) als perfekt bezeichnet. Sie ist in der Realität allerdings sehr selten, wie Axsäter (1986) feststellt, und wird deshalb in dieser Arbeit nicht weiter betrachtet.




Abbildung 2.6.: Beispiel für konsistente und inkonsistente Lösungen

säter (1986) dazu. In vielen Planungsaufgaben gibt es eine Reihe von Bedingungen, die eine Lösung erfüllen muss, damit sie realisierbar und gültig ist. Dabei können verschiedene Voraussetzungen und Bedingungen mit den verschiedenen Planungs- bzw. Aggregations-ebenen verknüpft sein. Nach Axsäter (1986) ist die Umsetzbarkeit einer Lösung auf einer aggregierten Ebene genau dann erfüllt, wenn durch Disaggregation eine detailliertere Lösung ermittelt werden kann, die den Bedingungen auf der entsprechend niedrigeren Aggregationsebene ebenfalls genügt. Das in diesem Abschnitt verwendete Beispiel der Personalplanung im Vertrieb enthält ein Beispiel für eine nicht umsetzbare Lösung. Werden einem Land bei der Zuteilung von Personal auf europäischer Ebene zu wenige Mitarbeiter zugeordnet, um die festgelegten Umsatzziele dieses Landes zu erreichen, dann ist diese Lösung entsprechend nicht umsetzbar.

Exemplarisch sei noch auf zwei Arbeiten hingewiesen, die die Bedeutung verschiedener Aggregationsebenen für eine Supply Chain beschreiben. Haberleitner u.a. (2010) erläutern den Einfluss unterschiedlicher Aggregationsebenen für eine Supply Chain, die feuerfeste Materialien produziert, während Roitsch und Meyr (2008) diesen Aspekt für eine Supply Chain in der Ölindustrie darstellen.

Modellierung von Planungsaufgaben

Ein weiterer wichtiger Bestandteil der HP ist die Übersetzung von Planungsaufgaben in ein Modell, das von Domschke u.a. (1997, S. 35) auch als *“ein vereinfachtes Abbild eines realen Systems oder Problems”* beschrieben wird. Im Fokus der HP stehen mathematische Modelle, wie bereits Stadtler und Fleischmann (2012) vermerken. Besonders häufig handelt es sich dabei um Optimierungsmodelle, die hier basierend auf den Ausführungen von Domschke u.a. (1997, S. 35–38) dargestellt werden.

Grundlage eines solchen Modells ist ein Vektor von Variablen. Die Variablen können verschiedene Ausprägungen aus einem vorgegebenen Wertebereich annehmen. Exemplarisch werden an dieser Stelle die beliebigen n Variablen x_1 bis x_n verwendet, die in dem Vektor $\mathbf{x} = (x_1, \dots, x_n)$ enthalten sind. Mögliche Wertebereiche für diese Variablen können unter anderem die natürlichen oder auch die reellen Zahlen sein.

Die zwei wesentlichen Komponenten in einem Optimierungsmodell sind dann eine zu optimierende Zielfunktion und ein System von Nebenbedingungen. Beispielfhaft wird an

dieser Stelle angenommen, dass letzteres System aus m Nebenbedingungen besteht. Eine einzelne Nebenbedingung ist dabei eine mathematische Gleichung oder Ungleichung. Eine beliebige j -te Nebenbedingung ist in Gleichung 2.1.1 beispielhaft dargestellt:

$$\sum_{i=1}^n a_{ji} \cdot x_i = b_j \quad (2.1.1)$$

Die Werte a_{ji} und b_j sind in einer solchen Nebenbedingung für alle i und j vorgegebene Inputwerte des Optimierungsmodells. Wie in dem folgenden Beispiel sind diese Inputwerte häufig natürliche oder reelle Zahlen. Eine konkrete Ausprägung aller Variablen im Vektor \mathbf{x} ist eine zulässige Lösung des Optimierungsmodells, wenn sie alle m Nebenbedingungen erfüllt. Die zweite wichtige Komponente des Modells ist die Zielfunktion $F(\mathbf{x})$, die in einem Optimierungsmodell entweder zu maximieren oder minimieren ist. Es gilt also die zulässige Lösung zu ermitteln, für die die Zielfunktion den maximalen bzw. minimalen Wert annimmt. Da es sich bei dem Optimierungsmodell um eine mathematische Abbildung der ursprünglichen Planungsaufgabe handelt, beschreibt die so erarbeitete Lösung auch deren optimale Ausgestaltung.

Exemplarisch sei an dieser Stelle folgende Situation beschrieben, die sich in einem einfachen Optimierungsmodell abbilden lässt: Eine Supply Chain kann die drei Produkte 1, 2 und 3 jeweils maximal einmal absetzen, die alle auf der einzigen vorhandenen Maschine produziert werden müssen. Die Maschine kann 8 Stunden betrieben werden und die Herstellung einer Mengeneinheit der Produkte 1, 2 und 3 dauert 5, 2 und 7 Stunden. Der Profit, den die Supply Chain mit den Produkten erwirtschaftet, beträgt €1000, €500 und €1400. Die Supply Chain will die Produkte erstellen, die ihren Profit maximieren. Das für diese Situation verwendete Optimierungsmodell entspricht dem Modell für das Knapsack-Problem, wie es unter anderem von Domschke und Scholl (1999, S. 37) oder Cormen u.a. (2001, S. 382–383) beschrieben wird. Es umfasst die drei binären Variablen x_1 , x_2 und x_3 , die sich auf die drei Produkte beziehen. Wenn $x_i = 1$, dann wird das Produkt i in der entsprechenden Lösung auch erstellt. Umgekehrt wird das Produkt i nicht produziert, wenn $x_i = 0$. Die zu maximierende Zielfunktion für dieses Problem ist nun in Gleichung 2.1.2 dargestellt.

$$F(\mathbf{x}) = 1000 \cdot x_1 + 500 \cdot x_2 + 1400 \cdot x_3 \quad (2.1.2)$$

Die Funktion gibt den resultierenden Profit für unterschiedliche Kombinationen produzierter Produkte wieder. Wichtig zu beachten ist dabei, dass nur die Lösungen gültig sind, die die Kapazitätsrestriktion durch die Maschine berücksichtigen. Sie wird durch die folgende einzige Nebenbedingung des Modells beschrieben:

$$5 \cdot x_1 + 2 \cdot x_2 + 7 \cdot x_3 \leq 8 \quad (2.1.3)$$

Für diverse Planungsaufgaben aus der Supply Chain Planung wurden bereits Modelle

entwickelt und veröffentlicht. Domschke u.a. (1997) stellen beispielsweise verschiedene Modelle zur Optimierung der Lagerhaltung und Losgrößenplanung, Fließbandabstimmung und Maschinenbelegung vor. Allgemein unterscheiden beispielsweise Domschke u.a. (1997) oder Stadtler (2008a) lineare und ganzzahlige Optimierungsmodelle. Bei einem linearen Optimierungsmodell können alle Variablen im Vektor $\mathbf{x} = (x_1, \dots, x_n)$ sämtliche reellen Werte innerhalb bestimmter modellspezifischer Schranken annehmen. In einem ganzzahligen Optimierungsmodell sind hingegen alle Variablen ganzzahlig oder wie im beschriebenen Knapsack-Problem binär. Können einige Variablen reelle und andere nur ganzzahlige Werte annehmen, so wird das Modell von Stadtler (2008a) als gemischt-ganzzahlig bezeichnet. Für die unterschiedlichen Arten von Optimierungsmodellen sind dabei meistens verschiedene Lösungsverfahren anwendbar.

Lösung bzw. Optimierung der erstellten Modelle

Abschließend werden die Unterschiede zwischen den verschiedenen Verfahren zur Lösung der Modelle in der HP beschrieben. Hervorzuheben ist dabei zunächst, wie unter anderem von Vogel (2014, S. 32–33) erläutert, dass die zerlegten Probleme in der hierarchischen Struktur unabhängig voneinander bearbeitet und gelöst werden. Damit steht die HP im Gegensatz zum monolithischen Ansatz, der die Probleme zusammenhängend betrachtet und optimiert. Eine wesentliche Motivation für dieses Vorgehen ist es, wie bereits zuvor dargelegt, die Komplexität des Modells und des damit verbundenen Lösungsverfahrens zu begrenzen.

Allgemein werden zwei Typen von Lösungsverfahren für Optimierungsmodelle unterschieden:⁷

1. Exakte Verfahren
2. Heuristiken

Die exakten Verfahren liefern dabei immer die gültige Lösung, für die die Zielfunktion den maximalen bzw. minimalen Wert annimmt. In dem zuvor beschriebenen Knapsack-Problem ist dies die Lösung $x_1 = 1$, $x_2 = 1$ und $x_3 = 0$, für die die Zielfunktion den maximalen Wert von 1500 ergibt. Besonders bei den linearen Optimierungsmodellen werden häufig exakte Verfahren verwendet, da sie mit akzeptablem Rechenaufwand die optimale Lösung bestimmen. Exemplarisch stellen Domschke u.a. (1997, S. 39–52) sowie Cormen u.a. (2001, S. 796–804) den Simplex-Algorithmus als ein solches exaktes Verfahren für lineare Optimierungsmodelle vor.

Für viele Modelle ist allerdings der Rechenaufwand zu hoch, um die optimale Lösung zu bestimmen. Domschke u.a. (1997, S. 52–57) sowie Cormen u.a. (2001, S. 966–1021) beschreiben beispielsweise eine Menge von Problemen, für die bisher kein Verfahren bekannt ist, das für alle möglichen Ausprägungen des damit verbundenen Modells innerhalb einer akzeptablen Rechenzeit die optimale Lösung bestimmt. Viele ganzzahlige bzw. gemischt-ganzzahlige Modelle, die allgemein als NP-vollständig bezeichnet werden, gehören dieser Menge an. Für diese Modelle werden häufig Heuristiken eingesetzt, die eine möglichst

⁷Zu dieser Unterscheidung vgl. zum Beispiel Domschke u.a. (1997, S. 39–52), Fleischmann u.a. (2008) oder Vogel (2014, S. 32–33).

gute und gültige aber nicht notwendigerweise die optimale Lösung des Problems mit einem deutlich geringeren Rechenaufwand ermitteln sollen. Eine solche Heuristik ist beispielsweise der genetische Algorithmus, der unter anderem von Klein (2008) erläutert wird.

Das Vorgehen der verschiedenen Lösungsverfahren wird hier allerdings nicht im Detail beschrieben, da sie für die untersuchten Fragestellungen in dieser Arbeit keine Relevanz haben.

2.1.2. Supply Chain Planning-Matrix

Das Konzept der HP ist für die Bearbeitung vieler Planungsaufgaben in einer Supply Chain nützlich. Es bleibt allerdings insofern abstrakt, als dass es sich nicht auf die konkret in einer Supply Chain anfallenden Planungsaufgaben bezieht. Es hilft nicht, diese Planungsaufgaben übergreifend zu strukturieren und die Zusammenhänge aufzuzeigen. Hierfür ist die bereits in Abbildung 1.1 dargestellte Supply Chain Planning-Matrix von Rohde u.a. (2000) geeigneter. Die Planungsaufgaben einer Supply Chain werden hier entlang zweier Dimensionen aufgegliedert. Dies ist zum einen der Zeithorizont einer Planungsaufgabe, der in der Abbildung auf der linken Seite vertikal dargestellt ist. Zum anderen wird die Relevanz der Planungsaufgabe für die unterschiedlichen Schritte eines generischen *Supply Chain Prozesses*⁸ berücksichtigt, der sich in die Schritte *Beschaffung*, *Produktion*, *Distribution* und *Absatz* unterteilt und in der Abbildung horizontal am oberen Rand abgebildet ist.

Wie bereits dem Zitat von Lambert u.a. (1998) zu Beginn von Abschnitt 2.1 entnommen werden kann, ist es die Aufgabe des Supply Chain Managements, die wichtigsten Geschäftsprozesse aufeinander abzustimmen. Eine Strukturierung der aus dieser Anforderung resultierenden Planungsaufgaben entlang eines generischen Supply Chain Prozesses erscheint deshalb sehr sinnvoll. Um die verschiedenen Planungsebenen in einer Supply Chain zu berücksichtigen, die ebenfalls zu Beginn von Abschnitt 2.1 beschrieben werden, ist die Verwendung des Zeithorizonts als zweite Dimension ebenfalls durchaus geeignet. Rohde u.a. (2000) ordnen die neun wesentlichen Planungsmodule aus der Supply Chain Planung in diese Matrix ein. Diese Module sind Grundlage vieler moderner Softwarelösungen zur Unterstützung der Supply Chain Planung, wie Rohde u.a. (2000) beschreiben. Sie dienen gleichzeitig als strukturierende Grundlage für die Erläuterung der verschiedenen Planungsaufgaben in einer Supply Chain in Abschnitt 2.2. In der von Fleischmann u.a. (2008) entwickelten Variante der Supply Chain Planning-Matrix, die in Abbildung 2.7 dargestellt ist, sind die konkreten Planungsaufgaben aufgeführt, die für die verschiedenen Schritte in dem generischen Supply Chain Prozess und für unterschiedliche Zeithorizonte relevant sind.

Verschiedene Prinzipien der HP werden auch in der Matrix angewendet. Wie von Fleischmann u.a. (2008) beschrieben, liegt der Supply Chain Planning-Matrix ebenfalls kein rein monolithischer Ansatz zugrunde. Die mit dem Supply Chain Management verbundenen Probleme werden entlang des generischen Supply Chain Prozesses und des Zeithorizonts

⁸Der Begriff Supply Chain Prozess wurde in diesem Zusammenhang bereits von Fleischmann u.a. (2008) verwendet.




Abbildung 2.7.: Supply Chain Planning-Matrix nach Fleischmann u.a. (2008)

in mehrere Teilprobleme zerlegt. Wie aus Abbildung 2.7 ersichtlich wird, formen diese Teilprobleme allerdings keine strikte Hierarchie wie bei der HP.

Auch bei der Koordination zwischen den Teilproblemen gibt es Gemeinsamkeiten und Unterschiede zur HP. Fleischmann u.a. (2008) erläutern die unterschiedlichen Informationsflüsse in der Supply Chain Planning-Matrix. Wie bei der HP kann eine Koordination der Probleme in Form von top-down Instruktionen sowie bottom-up Reaktionen und Antizipationen erfolgen. Dies ist in Abbildung 2.7 durch die vertikalen Informationsflüsse dargestellt. Es besteht allerdings auch die Möglichkeit, dass es zwischen Problemen mit dem gleichen Zeithorizont einen direkten Austausch gibt, der in Abbildung 2.7 durch die horizontalen Informationsflüsse illustriert wird. Wie Fleischmann u.a. (2008) beschreiben, verläuft der horizontale Informationsfluss meistens entgegengesetzt zum Supply Chain Prozess. Die erwarteten Nachfragemengen aus der Absatzplanung werden für Planungsaufgaben in der Distribution, Produktion und Beschaffung benötigt. Wie Fleischmann u.a. (2008) weiter feststellen, ist ein horizontaler Informationsfluss in die andere Richtung für viele Planungsaufgaben vorteilhaft und wünschenswert. So können beispielsweise Informationen aus der Beschaffung, wie die aktuellen Lagerbestände oder die Zeitdauer für die Wiederbeschaffung von Materialien, für die Produktionsplanung immens wichtig sein. Das Bereitstehen von Materialien, die für die Produktion bestimmter Produkte notwendig sind, kann dann in der Maschinenbelegungsplanung berücksichtigt werden.

Auch werden in der Supply Chain Planning-Matrix verschiedene Aggregationsebenen für die unterschiedlichen Planungsaufgaben verwendet. Mit einem zunehmenden Zeithorizont werden für die Planungsaufgabe stärker aggregierte Objekte benutzt. Bei der langfristigen Bestimmung von Standorten oder Produktionssystemen werden in der Planung

stärker aggregierte Objekte betrachtet als bei der Maschinenbelegungsplanung. Während bei der Erarbeitung der kurzfristigen Maschinenbelegungspläne eindeutig identifizierbare Produkte differenziert werden, sollte bei der Planung eines Produktionssystems eine aggregierte Menge von Produkten untersucht werden.

Die von Meyr u.a. (2008a,b) vorgestellten APS zur Unterstützung der verschiedenen Planungsaufgaben in der Supply Chain Planning-Matrix verfügen über diverse Funktionalitäten, um analog zur HP unterschiedliche Probleme zu modellieren und optimieren. Fleischmann u.a. (2008) beschreiben zwei Integrationsbeispiele eines solchen APS in die Supply Chain Planung. Sie heben hervor, dass ein APS auf die jeweils vorliegende Supply Chain mit seinen verschiedenen Planungsmodulen und individuell ausgestalteten Informationsflüssen zugeschnitten werden muss. Um die unterschiedlichen Eigenschaften von Supply Chains zu berücksichtigen, können in der Supply Chain Planung unterschiedliche Schwerpunkte gesetzt werden. Ist beispielsweise die Wiederbeschaffung von Materialien kurzfristig mit hoher Zuverlässigkeit möglich, dann werden die Planungsaufgaben zur Materialplanung eine geringere Rolle in der Supply Chain Planung spielen, als wenn die Zeitdauer für die Wiederbeschaffung verhältnismäßig lang ist und größeren Schwankungen unterliegt.

Eine Beschreibung der verschiedenen Planungsmodule folgt nun im nächsten Abschnitt.

2.2. Planungsmodule der Supply Chain Planning-Matrix

Die im letzten Abschnitt skizzierte Supply Chain Planning-Matrix mit ihren verschiedenen Planungsmodulen wurde bereits in zahlreichen Veröffentlichungen detailliert beschrieben. Exemplarisch seien an dieser Stelle die Arbeiten von Rohde u.a. (2000), Fleischmann u.a. (2008) und Stadtler und Fleischmann (2012) genannt. Die Ausführungen in diesem Abschnitt beziehen sich auf diese Arbeiten.

Die Inhalte der neun Planungsmodule werden nun nacheinander erläutert.

Strategic Network Design

Eine detaillierte Beschreibung dieses Planungsmoduls wird von Goetschalckx und Fleischmann (2008) präsentiert. Die Ausführungen in diesem Abschnitt bauen auch auf dieser Arbeit auf. Aufgabe dieses Planungsmoduls ist es, die Supply Chain auszugestalten bzw., wie Rohde u.a. (2000) oder Goetschalckx und Fleischmann (2008) schreiben, zu konfigurieren. Dabei werden folgende typische Fragestellungen in den angeführten Veröffentlichungen genannt, die innerhalb des Strategic Network Designs bearbeitet werden:

- Wer sind die Zielkunden und -märkte?
- Welche Produkte sollen angeboten werden?
- Wie sieht das Produktionssystem und das Distributionsnetzwerk für diese Produkte und Kunden aus?
- Welche Produktionsstandorte sollen einbezogen werden?

- Welche Materialien werden für die Produktion benötigt und welche Lieferanten werden ausgewählt?
- Gibt es sinnvolle Partnerschaften oder Kooperationen für die Supply Chain und wie können diese ausgestaltet werden?

Zielsetzung des Strategic Network Designs ist es dabei meistens, die Supply Chain so auszugestalten, dass bestimmte Finanzkennzahlen optimiert werden. Goetschalckx und Fleischmann (2008) nennen hier exemplarisch die Profitmaximierung oder Kostenminimierung.

Die Planungsaufgaben im Strategic Network Design haben eine hohe Relevanz für eine Supply Chain. Die hier getroffenen Entscheidungen haben meistens großen Einfluss auf die finanzielle Entwicklung einer Supply Chain. So sind mit der Umstellung des Produktionssystems oder Distributionsnetzwerks sowie der Eröffnung eines neuen Produktionsstandorts üblicherweise größere Investitionen verbunden. Gleichzeitig hat die Auswahl der Zielkunden und der angebotenen Produkte eine immense Bedeutung für die zukünftige Umsatzentwicklung. Eine fehlerhafte Planung kann entsprechend zu großen Fehlinvestitionen und Umsatzeinbußen führen. Das mit diesen Planungsaufgaben verbundene Risiko ist deshalb groß.

Wie bereits in Abschnitt 2.1 dargestellt, haben die Entscheidungen auf dieser strategischen Planungsebene einen langfristigen Zeithorizont und werden vom Top-Management getroffen. Für die Planung wird dabei meistens eine höhere Aggregationsebene verwendet. Trotzdem ist hervorzuheben, dass diese Form der Planung nicht nur einmalig durchgeführt und danach nicht mehr überarbeitet wird. Wie Goetschalckx und Fleischmann (2008) beschreiben, ist es für den langfristigen Erfolg einer Supply Chain sehr wichtig, Marktentwicklungen genau zu beobachten und die Supply Chain durch strategische Neuausrichtungen auf eine veränderte Situation rechtzeitig einzustellen. Ein klassisches Beispiel für eine solche Veränderung der Marktsituation sind technologische Weiterentwicklungen, die eine Supply Chain berücksichtigen muss, um auch zukünftig mit ihren Produkten konkurrenzfähig zu sein.

Die im Rahmen des Strategic Network Designs getroffenen Entscheidungen haben direkten Einfluss auf alle anderen Planungsaufgaben in der Supply Chain Planning-Matrix. Es ist dabei hervorzuheben, dass bei dieser Planung meistens ein holistischer Ansatz verwendet wird, der die Supply Chain ganzheitlich betrachtet, weil sich hier viele Planungsaufgaben gegenseitig beeinflussen. So kann die Auswahl der Zielkunden große Bedeutung für die Produktionsstandorte und das Distributionsnetzwerk haben, da die Distanzen für die Auslieferung nicht unnötig groß sein sollten. Gleichzeitig ist die Auswahl der Lieferanten oft an die Produktionsstandorte gebunden. Umgekehrt können die infrastrukturellen Voraussetzungen und die gegebenenfalls damit verbundenen Einschränkungen für die Produktion von Bedeutung für die Auswahl der Zielkunden und Märkte sein. Um diese Zusammenhänge und die Notwendigkeit eines holistischen Ansatzes hervorzuheben, wird in Abbildung 2.7 im letzten Abschnitt eine einzige Box verwendet, die alle langfristig strategischen Planungsaufgaben umfasst.

Demand Planning

Die Vorstellungen dieses Planungsmoduls von Kilger und Wagner (2008) sowie Meyr (2012) sind zusätzliche Grundlage für die Ausführungen in diesem Abschnitt zum Demand Planning. Die wesentliche Aufgabe dieses Planungsmoduls ist die Vorhersage der zukünftigen Nachfrage für einen mittel- bis kurzfristigen Zeithorizont. In einer Supply Chain werden häufig Entscheidungen zu einem Zeitpunkt getroffen, zu dem konkrete Bestellungen noch nicht vorliegen und damit die tatsächliche Nachfrage nicht bekannt ist. Ein klassisches Beispiel, das von Kilger und Wagner (2008) angeführt wird, bezieht sich auf einen Produzenten von Konsumgütern. Diese kaufen die Kunden häufig direkt aus dem Regal in einem Geschäft. Die Supply Chain muss die Güter also für ihre Kunden produzieren, um damit die Regale zu füllen, bevor die tatsächliche Kundennachfrage bekannt ist. Es ist nun die wesentliche Aufgabe des Demand Plannings, diese unbekannte Nachfrage zu prognostizieren, damit diese Information für andere Planungsaufgaben verwendet werden kann. In dem Konsumgüterbeispiel müssen beispielsweise die Produktionsmengen oder der Einkauf von Materialien auf Basis von Nachfrageprognosen geplant werden.

Die in Kapitel 1 beschriebene Analyse der ADI-basierten Prognosemethode bezieht sich auf dieses Planungsmodul. Eine genaue Einordnung der in dieser Arbeit durchgeführten Analyse und ihrer Bedeutung für das Demand Planning erfolgt in Abschnitt 2.5. In diesem Abschnitt sowie Kapitel 7 wird das Demand Planning noch detaillierter beschrieben. Dabei werden die typischen Vorgehensweisen und Methoden des Demand Plannings erläutert.

Demand Fulfillment

Das Demand Fulfillment wird unter anderem von Knolmayer u.a. (2002, S. 147–149), Ball u.a. (2004), Fleischmann und Meyr (2004), Kilger und Meyr (2008) sowie Vogel (2014, S. 81–105) beschrieben. Diese Arbeiten dienen als weitere Grundlage für die Ausführungen in diesem Abschnitt.⁹

Aufgabe des Demand Fulfillments ist die Planung und Umsetzung der vorliegenden Kundenaufträge. Eine wichtige Komponente dieses Planungsmoduls ist dabei das *Order Promising*, dessen Ziel es ist, einen ersten Liefertermin für einen Auftrag zu bestimmen und dem Kunden mitzuteilen. Die Erfüllung dieses Termins hat später großen Einfluss auf die Kundenzufriedenheit. Es existieren zahlreiche Verfahren, um im Rahmen des Order Promisings den Liefertermin zu bestimmen. Diese werden an dieser Stelle nicht detailliert beschrieben. Exemplarisch für ein solches Verfahren wird hier auf die Arbeit von Vogel (2014) verwiesen.

Eine wichtige Maßeinheit, um die Qualität der bestimmten Liefertermine zu bewerten, ist der Auftragsanteil, der pünktlich an den Kunden ausgeliefert wurde. Desto mehr Aufträge den Kunden zum versprochenen Liefertermin erreichen, umso zuverlässiger und besser ist die Planung des Order Promisings zu beurteilen. Es ist dabei zu berücksichtigen, dass

⁹Ein Überblick zu weiteren Veröffentlichungen in diesem Themenkomplex enthalten Kilger und Meyr (2008) sowie Pibernik (2005). Konkrete Rahmenwerke und Modelle zur Unterstützung des Demand Fulfillments werden unter anderem in Fleischmann und Meyr (2004), Chen u.a. (2001, 2002), Jeong u.a. (2002), Pibernik (2005) sowie Vogel (2014) vorgestellt.

es nicht möglich ist, dem Kunden einen Liefertermin zu nennen, der beliebig weit in der Zukunft liegt, um dadurch die rechtzeitige Auslieferung zu gewährleisten. Die eigene Lieferfähigkeit ist bei der Bestimmung des Liefertermins miteinzubeziehen. Gollwitzer und Karl (1998, S. 68–71) unterscheiden in diesem Zusammenhang drei Lieferzeitpunkte:

1. Den Wunschlieferzeitpunkt
2. Den dem Kunden versprochenen Lieferzeitpunkt
3. Den tatsächlichen Lieferzeitpunkt

Durch den Abgleich des zweiten und dritten Lieferzeitpunkts kann der Auftragsanteil bestimmt werden, den der Kunde zum versprochenen Zeitpunkt erhalten hat, und damit die Liefertreue bewertet werden. Bei der Bestimmung des Liefertermins im Order Promising muss allerdings der Wunschlieferzeitpunkt des Kunden beachtet werden. Weicht der ermittelte Termin zu weit vom Wunschlieferzeitpunkt ab, besteht die Gefahr, dass der Kunde den Auftrag storniert und stattdessen ein Konkurrenzprodukt erwirbt.

Neben dem Order Promising ist die Planung und Steuerung aller verbleibenden Schritte zur Erfüllung eines vorliegenden Kundenauftrags die zweite wesentliche Komponente des Demand Fulfillments. Dieser von Vogel (2014, S. 81–105) als *Order Fulfillment* bezeichnete und dargestellte Vorgang erfolgt nach der Bestimmung des ersten Liefertermins im Order Promising. Ziel des Order Fulfillments ist es, die bestellten Produkte möglichst kostengünstig und zum versprochenen Zeitpunkt auszuliefern, wie Fleischmann und Meyr (2004) schreiben.

Master Planning

Außer auf die Ausführungen von Rohde u.a. (2000) stützt sich dieser Abschnitt auf der Arbeit von Rohde und Wagner (2008). Kernaufgabe des Master Plannings ist die mittelfristige Koordination der Materialflüsse im Supply Chain Prozess von der Materialbeschaffung bis zur Auslieferung an den Kunden. Grundlage dieser Planung sind die im Rahmen des Demand Plannings ermittelten mittelfristigen Nachfragemengen.

Das Master Planning muss also die zukünftige Nachfrage mit den zur Verfügung stehenden Kapazitäten entlang des Supply Chain Prozesses abstimmen. Dabei sind für diese Planung diverse Eigenschaften der Supply Chain, der erzeugten Produkte sowie des Marktes zu berücksichtigen.

Für das Master Planning wird zunächst immer die Zeit in diskrete Abschnitte bis zum Planungshorizont aufgeteilt. Diese Zeitabschnitte können beispielsweise Wochen, Monate oder Quartale sein. Wichtig ist, dass das Master Planning mindestens einen vollständigen Saisonzyklus mit allen Zeitabschnitten hoher und niedriger Nachfrage umfasst. In den meisten Fällen beträgt der Zeithorizont ein ganzes Jahr, das in die Planungen einbezogen werden muss.

Eine entscheidende Rolle spielt ebenfalls die Lagerfähigkeit von Zwischen- und Endprodukten. Im Rahmen des Master Plannings ist dabei zu klären, ob es möglich ist, überschüssige Mengen in Zeiten niedriger Nachfrage vorzuproduzieren und einzulagern, um sie in Zeiten höherer Nachfrage, der Hochsaison, abzusetzen. Diese Fragestellung ist vor allem dann von großer Bedeutung, wenn die Nachfrage in der Hochsaison die Kapazität

der Supply Chain übersteigt. Während des Master Plannings sind dabei diverse Eigenschaften der Supply Chain zu beachten, um einen guten Plan zu entwickeln. Dies umfasst unter anderem folgende Eigenschaften:

- Lagerfähigkeit und -kosten verschiedener Produkte
- Zeitrahmen und Kosten für Überstunden in der Produktion
- Möglichkeit und Kosten einer Verlagerung von Aufträgen auf andere Produktionsstandorte
- Möglichkeit und Kosten einer Auslagerung von Aufträgen oder einzelner Produktionsschritte an Dritte
- Opportunitätskosten aus nicht bedienter Nachfrage
- Verwendung verschiedener Distributionswege

Die Durchführung dieser Planung kann sehr aufwendig sein, weshalb bestimmte Objekte aggregiert betrachtet werden müssen, um die Komplexität zu reduzieren. Wie von Rohde u.a. (2000) beschrieben, werden dabei häufig Produkte, Materialien oder Produktionsressourcen in Aggregationsebenen zusammengefasst. Gleichzeitig sollte sich die Planung auf Endprodukte und Engpässe in der Produktion fokussieren, die für die mittelfristige Abstimmung von Nachfrage und Kapazität besonders relevant sind. Rohde und Wagner (2008) stellen ferner fest, dass durch die Betrachtung von Aggregationsebenen das Risiko einer Abweichung der tatsächlichen von der prognostizierten Nachfrage und damit einer Fehlplanung sinkt.

Typische Ergebnisse des Master Plannings umfassen nach Rohde u.a. (2000) die mittelfristigen Produktionsmengen je Standort und Zeitabschnitt, die damit verbundenen Personalanforderungen und Beschaffungsmengen je Zeitabschnitt, die zu erwartenden Lagerbestände sowie die zu transportierenden Mengen.

Die Ergebnisse des Master Plannings dienen als Vorgabe für die verbleibenden noch nicht beschriebenen fünf Planungsmodule.

Production Planning und Scheduling

Unter Berücksichtigung der Ergebnisse aus dem Master Planning wird in diesen beiden Modulen die kurzfristige Planung der Produktion vorgenommen. Wie bereits Rohde u.a. (2000) festgestellt haben, ist der Übergang zwischen den beiden Modulen häufig fließend, weshalb sie an dieser Stelle zusammen betrachtet werden. Weitere Details zum Production Planning und Scheduling werden unter anderem von Domschke u.a. (1997) sowie Stadtler (2008b) beschrieben. Auf diese Arbeiten wird in den folgenden Ausführungen ebenfalls zurückgegriffen.

Das Ergebnis aus diesen beiden Modulen ist ein Plan, der unter anderem genau wiedergibt, welche spezifischen Produkte auf welchen Produktionsressourcen in welcher Reihenfolge und zu welchem Zeitpunkt gefertigt werden. Der Zeithorizont für diese Planung ist abhängig von diversen Eigenschaften der Supply Chain und kann zwischen einem Tag

und einigen Wochen betragen. Außerdem sollte diese Planung dezentral in der unmittelbaren Umgebung des Produktionsstandorts durchgeführt werden, um zu gewährleisten, dass das vorhandene Wissen zur aktuellen Situation in der Fertigung ausreichend beachtet wird. Dies kann beispielsweise Wissen zum Zustand der Produktionsressourcen, zu den vorhandenen Materiallagerbeständen oder zur Verfügbarkeit der Belegschaft sein. Alle diese Punkte haben direkten Einfluss auf die Fertigung und sind direkt am Produktionsstandort meistens am genauesten bekannt.

Wie bereits beschrieben, ist der Übergang zwischen Production Planning und Scheduling oft fließend. Im Rahmen des Production Plannings werden konkrete Pläne erstellt, die die in einer Schicht oder an einem Tag zu fertigenden Produkte auflisten. Im Scheduling wird dann unter Berücksichtigung der Rüstzeiten die konkrete Reihenfolge ermittelt, in der diese Produkte innerhalb einer Schicht oder eines Tages erzeugt werden. In Abhängigkeit von der Art der Fertigung kann dabei das Production Planning und Scheduling simultan oder nacheinander durchgeführt werden, weshalb eine Differenzierung der beiden Module nicht in jeder Supply Chain trennscharf möglich ist.

Material Requirements Planning

Die Arbeit von Stadtler (2008c) führt in dieses Planungsmodul ein und dient als weitere Grundlage für die folgenden Darstellungen.

Die wesentliche Aufgabe des Material Requirements Plannings ist es, dafür zu sorgen, dass die für die Produktion notwendigen Materialien bereitstehen. Das Planungsmodul erhält dafür als Input aus dem Production Planning und Scheduling sowie dem Master Planning Informationen über die geplanten Produktionsmengen. Aus dieser Information müssen die zukünftig für die Produktion benötigten Materialmengen abgeleitet werden, und es muss sichergestellt sein, dass diese der Produktion rechtzeitig zur Verfügung stehen. Als Grundlage für diese Ableitung dient die Materialstückliste, die auch als *Bill of Material* bekannt ist und wiedergibt, welche Materialien für die Fertigung eines Produkts gebraucht werden.

Das Material Requirements Planning muss die entsprechenden Materialien bei den Lieferanten der Supply Chain bestellen. Es muss dabei die vorhandenen Materiallagerbestände sowie die Zeitdauer von Auftragsabgabe bis Materialeingang berücksichtigen und die Bestellung mit ausreichend Vorlaufzeit platzieren. Gleichzeitig gibt das Modul Informationen über die Materialverfügbarkeit an das Production Planning und Scheduling, damit diese in die Produktionsplanung einbezogen werden können, wie Rohde u.a. (2000) ausführen.

Außerdem werden im Rahmen des Material Requirements Plannings die endgültigen Konditionen mit den Lieferanten ausgehandelt, wobei gegebenenfalls vorhandene Rahmenverträge zu beachten sind. Das Material Requirements Planning zielt dabei meistens darauf ab, die benötigten Materialien in entsprechender Qualität zu möglichst günstigen Konditionen zu bekommen. Dafür sind durch das Modul diverse Aspekte wie die Lagerhaltungskosten für die Materialien, Mengenrabatte oder Vergünstigungen für längere Vorlaufzeiten bei den Bestellungen zu beachten. Zusätzlich sollte das Material Requirements Planning den Markt für die eingekauften Materialien fortlaufend überwachen, um alternative Bezugsquellen frühzeitig zu identifizieren.

Distribution und Transportation Planning

Abschließend werden hier nun die beiden Planungsmodule Distribution Planning und Transportation Planning zusammen vorgestellt. Die Beschreibungen stützen sich dabei auch auf die Arbeit von Fleischmann (2008), der diese Module detailliert erläutert hat. Ziel dieser beiden Module ist es, die rechtzeitige Auslieferung der Waren an den Kunden möglichst kostengünstig zu gestalten. Grundlage für diese Planung ist das Distributionsnetzwerk, das im Rahmen des Strategic Network Designs ausgestaltet wird. Ein solches Netzwerk kann aus mehreren Stufen zwischen Produktionsstandort und Kunden bestehen. Dabei werden häufig regionale Verteilungszentren als Zwischenstufe in der Auslieferung verwendet. Solche Zentren werden oft in unmittelbarer Nähe zahlreicher Kunden positioniert. Sie erlauben es einer Supply Chain, die Bestellungen mehrerer Kunden für den Transport vom Produktionsstandort zum Verteilungszentrum zu bündeln. Dies kann zu Kostenvorteilen führen, wenn die Bestellung eines einzelnen Kunden nicht genügt, um die Kapazität eines bestimmten Transportmediums voll auszunutzen. Ein gutes Beispiel hierfür ist die Nutzung von standardisierten Containern in der Seefracht. Oft ist ein Großteil der Containerkosten fix und unabhängig von deren Befüllung. Eine Supply Chain möchte entsprechend hauptsächlich vollständig gefüllte Container verschicken, um die Anzahl benötigter Container und damit die gesamten Transportkosten zu reduzieren. Sie fasst deshalb die Bestellungen mehrerer Kunden für den Transport in einem Container zusammen. Die Waren werden anschließend im Verteilungszentrum für die Auslieferung zum Endkunden auf weitere Transportmedien disponiert. Gleichzeitig enthält ein solches Verteilungszentrum häufig noch ein regionales Lager mit Endprodukten. Ein solches Lager erlaubt der Supply Chain, kurzfristige Kundenbestellungen schneller auszuliefern. Diverse Aspekte sind für die Ausgestaltung des Distributionsnetzwerkes relevant. Neben der geographischen Verteilung der Kunden sind beispielsweise einige Produkteigenschaften für die Auslieferung wichtig. Dies umfasst Eigenschaften wie das Gewicht, die Abmessungen oder die Haltbarkeit der Produkte. Aus diesen Eigenschaften können direkte Anforderungen an das Distributionsnetzwerk abgeleitet werden. Die Erhaltung der Kühlkette ist in diesem Zusammenhang ein bekanntes Beispiel aus der Lebensmittelindustrie, wie unter anderem Krüger und Böckle (2007) beschreiben.

Ein weiterer wichtiger Aspekt für die Transportplanung ist die Verwendung verschiedener Transportwege mit unterschiedlichen Geschwindigkeiten. Neben der bereits erwähnten Seefracht ist beispielsweise im internationalen Warenverkehr die Luftfracht eine häufig eingesetzte Alternative, die meistens eine schnellere aber auch teurere Auslieferung erlaubt. Bei der Auswahl des Transportweges sind unter anderem auch der versprochene Liefertermin sowie die mit dem Kunden ausgehandelten Konditionen und an dieser Stelle insbesondere die Verteilung der Transportkosten zu berücksichtigen. Hier bieten bei internationalen Geschäften aktuell die Incoterms®[®], die von Ramberg (2011) detailliert dargestellt werden, einen häufig verwendeten Rahmen.

Das Distributionsnetzwerk wird im Rahmen des Strategic Network Designs langfristig ausgestaltet. Distribution und Transportation Planning verwenden es als Grundlage für die mittel- bis kurzfristige Planung zur Auslieferung der Produkte. Der Schwerpunkt des Distribution Plannings liegt dabei auf dem mittelfristigen Zeithorizont, während das Transportation Planning auf die kurzfristige Planung fokussiert ist.

Das mittelfristige Distribution Planning erhält als Vorgabe aus dem Production Planning und Scheduling sowie dem Master Planning die vorgesehenen Produktionsmengen. In diesem Modul werden dann vor allem die Transportmengen zwischen den Produktionsstandorten und den Verteilungszentren des Distributionsnetzwerks geplant. Dabei können, wie beschrieben, Aufträge mehrerer Kunden für den Transport gebündelt werden. Die Auswahl des geeigneten Transportwegs aus einem Satz vorgegebener Alternativen ist auch Aufgabe dieses Planungsmoduls. Außerdem muss das Distribution Planning die Kapazitäten und Kosten der vorhandenen Transportwege und Lager beachten, um die Auslieferung möglichst kostengünstig zu gestalten.

Das kurzfristige Transportation Planning konzentriert sich auf die endgültige Auslieferung der Produkte an die Kunden. Typische Problemstellungen dieses Planungsmoduls befassen sich mit der optimalen Ausgestaltung von Auslieferungstouren oder der Beladung der dafür verwendeten Transportmedien, wie von Rohde u.a. (2000) beschrieben. Eine in diesem Zusammenhang intensiv untersuchte Planungsaufgabe ist das *Vehicle Routing Problem* (VRP).¹⁰ Ziel des VRPs ist es, die Routen der bereitstehenden Transporter so zu planen, dass ein bestimmter Aspekt der Auslieferung optimiert wird. Dies können beispielsweise die Kosten oder die Zeitdauer für die Auslieferung sein. Die Transporter haben eine begrenzte Kapazität und die Waren befinden sich in einem zentralen Lager, zu dem die Transporter am Ende wieder zurückkehren sollen. Die Abstände zwischen den Kunden variieren. Beim klassischen VRP werden die Routen berechnet und anschließend von den Transportern vollständig abgefahren. Das dynamische VRP ist eine Variante dieses Problems, das, wie Pillac u.a. (2013) beschreiben, durch die technologische Entwicklung und den damit verbundenen Möglichkeiten zunehmend an Bedeutung gewinnt.¹¹ Im Gegensatz zum klassischen können beim dynamischen VRP die Routen während der Auslieferung auf Basis zwischenzeitlich eingegangener Bestellungen angepasst werden. So können kurzfristige Bestellungen schneller berücksichtigt und die Waren an den Kunden ausgeliefert werden.

Bedeutung untersuchter Fragestellungen für Planungsmodule

Wie bereits in Kapitel 1 dargestellt, ist diese Arbeit auf die Untersuchung von zwei wesentlichen Fragestellungen fokussiert:

1. Die Eignung von ADI-basierten Prognosemethoden in unterschiedlichen Situationen

¹⁰Das VRP wurde ursprünglich von Dantzig und Ramser (1959) vorgestellt. Toth und Vigo (2001) untersuchen das Problem detailliert. Sie stellen dabei sowohl verschiedene Varianten des Problems als auch unterschiedliche Lösungsansätze vor. Eine Erweiterung berücksichtigt beispielsweise Zeitfenster für die Auslieferung bei den verschiedenen Kunden. Für das VRP und die Varianten werden weiterhin regelmäßig neue Lösungsverfahren entwickelt. Beispiele sind Rei u.a. (2010) sowie Groër u.a. (2011).

¹¹Pillac u.a. (2013) stellen das dynamische VRP vor und geben eine detaillierte Übersicht über die Veröffentlichungen zu diesem Problem. Wie sie beschreiben, haben die Einführung des Global Positioning Systems (GPS), die zunehmende Verbreitung von mobilen Telefonen bzw. Smartphones sowie die Verfügbarkeit von genaueren Geographic Information Systems (GIS) den Supply Chains neue Möglichkeiten bei der Planung und Anpassung ihrer Auslieferungsrouten eröffnet. Der aktuelle Auslieferungsfortschritt kann so jederzeit überwacht, anschließend auf Grundlage einer veränderten Situation die Routen neu berechnet und eine Anpassung problemlos direkt übermittelt werden.

2. Der Einfluss des Bestellverhaltens auf das Entkopplungspunktkonzept

Die erste Fragestellung bezieht sich auf die Prognose zukünftiger Nachfrage und ist damit vor allem für das Demand Planning wichtig. Eine detaillierte Beschreibung der Bedeutung dieser Untersuchung für das Planungsmodul erfolgt in Abschnitt 2.5. Das Entkopplungspunktkonzept ist für verschiedene Planungsmodule aus der Supply Chain Planning-Matrix relevant. Es betrifft insbesondere das Strategic Network Design sowie mehrere kurzfristig operative Planungsmodule. Nach einer allgemeinen Erläuterung des Entkopplungspunktkonzepts in Abschnitt 2.3 wird in Abschnitt 2.4 die Relevanz der untersuchten Fragestellung für diese Planungsmodule erklärt.

2.3. Das Entkopplungspunktkonzept

Der Entkopplungspunkt markiert eine in den folgenden Ausführungen beschriebene Stelle in der Wertschöpfungskette einer Supply Chain. Eine Wertschöpfungskette umfasst dabei nach Porter (2014, S. 61–85) sämtliche Schritte in einer Supply Chain, die auf die Bereitstellung eines Produktes abzielen. Neben den kurz- bis mittelfristigen Schritten eines Supply Chain Prozesses zur physischen Herstellung und zum Vertrieb eines Produkts, die beispielhaft in der Supply Chain Planning-Matrix aufgeführt sind und von Porter (2014, S. 61–85) als primäre Aktivitäten bezeichnet werden, beinhaltet die Wertschöpfungskette auch unterstützende Tätigkeiten. Unterstützende Tätigkeiten sind unter anderem für die längerfristige Koordination und Planung der primären Tätigkeiten sowie die Weiterentwicklung der Supply Chain notwendig. Porter (2014, S. 61–85) nennt exemplarisch Aufgaben aus der Technologieentwicklung oder dem Personalwesen als unterstützende Aktivitäten.

Die erste dem Autor bekannte explizite Definition des Entkopplungspunkts stammt von Sharman (1984).¹² Diese ursprüngliche Definition des Entkopplungspunkts wurde von zahlreichen Autoren aufgegriffen, verändert und weiterentwickelt. Nicht alle diese Definitionen sind dabei deckungsgleich. Exemplarisch seien an dieser Stelle die Arbeiten von Hoekstra und Romme (1991, S. 6 ff.), Fleischmann und Meyr (2004), Vollmann u.a. (2005, S. 20 ff.), Olhager (2010) und Jeong (2011) genannt, die alle Definitionen des Konzepts enthalten, die sich teilweise sogar ähnlich aber eben nicht identisch sind.

Für die folgende Analyse des Zusammenhangs zwischen dem Bestellverhalten und dem Entkopplungspunkt ist eine eindeutige und trennscharfe Definition des Konzepts wichtig. Die Bedeutung von Kernaspekten des Entkopplungspunktkonzepts muss ohne Raum für Interpretation beschrieben werden. Die zuvor genannten Arbeiten werden dabei zwar berücksichtigt, die hier verwendete Definition des Entkopplungspunkts orientiert sich

¹²Sharman (1984) nennt den Entkopplungspunkt noch *order penetration point*. In vielen anderen Veröffentlichungen wird er als *customer order decoupling point* (vgl. bspw. Olhager (2010)) oder einfach nur *decoupling point* (vgl. bspw. Fleischmann und Meyr (2004)) bezeichnet.

Bereits vor der Arbeit von Sharman (1984) wurden Untersuchungen in verwandten Themenbereichen durchgeführt, die dem Entkopplungspunktkonzept sehr nah sind. Beispielhaft sei an dieser Stelle die Arbeit von Alderson (1950) genannt, deren Ergebnisse später noch beschrieben werden. Eine explizite Definition des Entkopplungspunktkonzepts findet sich in diesen Arbeiten allerdings nicht.

aber besonders stark an der von Meyr (2003), die diese Eindeutigkeit im Wesentlichen gewährleistet.

Der Entkopplungspunkt wird als späteste Stelle in einer Wertschöpfungskette definiert, nach der sämtliche Schritte nur noch auf Basis eines vorliegenden Auftrags durchgeführt werden. Das bedeutet, dass mit den Schritten nach dem Entkopplungspunkt nur begonnen wird, wenn dafür ein Kundenauftrag vorliegt.¹³ In Abbildung 2.8 wird das Entkopplungspunktkonzept exemplarisch illustriert. Die weißen Schritte nach dem Entkopplungspunkt werden entsprechend der Definition nur bei Vorliegen eines Kundenauftrags ausgeführt. Meyr (2003) nennt die Dauer dieser Schritte nach dem Entkopplungspunkt bis zum Abschluss der Wertschöpfungskette auch *Lieferzeit*. Die Wertschöpfungskette endet dabei mit der Auslieferung der bestellten Güter an den Kunden. Die beiden Schritte, die schwarz markiert sind, liegen vor dem Entkopplungspunkt. Sie werden in der Supply Chain auf Basis von Vorhersagen der zukünftigen Nachfrage geplant und gesteuert, weil zu diesem Zeitpunkt nicht unbedingt schon Bestellungen vorliegen. Die Zeitdauer zur Durchführung der Schritte vom Beginn der Wertschöpfung bis zum Entkopplungspunkt wird von Meyr (2003) als *Wiederbeschaffungszeit* bezeichnet. Die erste Tätigkeit ist dabei meistens die Bestellung der notwendigen Materialien für die Fertigung.

Wie von Meyr (2003) erläutert, ist die Lieferzeit der Lieferanten deshalb auch Teil der in Abbildung 2.8 illustrierten Wertschöpfungskette und somit Teil der Wiederbeschaffungszeit. Falls die Kunden der Supply Chain die erzeugten Güter weiterverarbeiten, ist die Lieferzeit der Supply Chain Teil der Wiederbeschaffungszeit ihrer Kunden. Wie bei Meyr (2003) ist die Lieferzeit als Teil einer Wiederbeschaffungszeit höchstens so lang wie diese. Die Wiederbeschaffungszeit der betrachteten Supply Chain ist also mindestens so lang wie die Lieferzeit ihrer Lieferanten. Umgekehrt ist die Wiederbeschaffungszeit der Kunden mindestens so lang wie die Lieferzeit der betrachteten Supply Chain.

In den meisten Definitionen des Entkopplungspunkts wird hervorgehoben, dass an dieser Stelle in der Wertschöpfung eine Lagerhaltung stattfindet.¹⁴ Die Produktionsmengen

¹³An diesem Punkt kann sehr gut hervorgehoben werden, wie sich die verschiedenen Definitionen des Entkopplungspunkts teilweise unterscheiden. Bei Meyr (2003) muss im Gegensatz zu Olhager (2010) der Kundenauftrag für die Produktion eines Gutes nur vorliegen. Produkte in der Wertschöpfungskette, die noch keinem Auftrag fest zugeordnet wurden, werden von Meyr (2003) als disponibler Bestand bezeichnet. Die Zuordnung des disponiblen Bestands zu den eingehenden Kundenaufträgen wird von ihm als Demand-Supply-Matching bezeichnet. Meyr (2003) schreibt, dass ein solches Demand-Supply-Matching auch nach dem Entkopplungspunkt noch vorgenommen bzw. verändert werden kann. Eine dauerhafte Zuordnung eines Produkts zu einem Auftrag ist für die Schritte nach dem Entkopplungspunkt nicht notwendig. Gehen beispielsweise mehrere Bestellungen für das gleiche Produkt ein, kann mit den Schritten nach dem Entkopplungspunkt ohne eine feste Zuordnung begonnen werden.

Bei Olhager (2010) ist dies anders. Er fordert für die Schritte nach dem Entkopplungspunkt eine feste Zuordnung von Produkten zu Bestellungen. Olhager (2010) geht auch davon aus, dass in den meisten Fällen sämtliche Produktspezifikationen nach dem Entkopplungspunkt unveränderlich festgeschrieben werden.

Meyr (2003) hingegen differenziert hier zwei Punkte. Neben dem Entkopplungspunkt bezeichnet er die Stelle, ab dem für Folgeschritte eine feste Zuordnung von Produkten zu Bestellungen notwendig ist, als *Freeze Point*. Er liegt wie von Meyr (2003) beschrieben niemals vor dem Entkopplungspunkt. Der Freeze Point wird in dieser Arbeit aber nicht weiter untersucht.

¹⁴Vgl. exemplarisch Hoekstra und Romme (1991, S. 6 ff.), Meyr (2003) oder Fleischmann und Meyr




Abbildung 2.8.: Produktionsschritte vor und nach dem Entkopplungspunkt

werden bis zu dieser Stelle auf Grundlage von Vorhersagen geplant und die Produkte in ihrem aktuellen Zustand nach Abschluss des letzten Schritts vor dem Entkopplungspunkt eingelagert. Die entsprechenden Mengen werden diesem Lager entnommen, sobald eine Bestellung vorliegt und mit den Schritten nach dem Entkopplungspunkt fortgefahren werden kann.

Fleischmann und Meyr (2004) schreiben, dass die Lagerhaltung wichtig ist, um eine Abweichung der tatsächlichen Nachfrage von der Prognose durch Sicherheitsbestände abfangen zu können. Wenn die tatsächliche Nachfrage die vorhergesagte übersteigt, können die Sicherheitsbestände verwendet werden, um die Differenz kurzfristig auszugleichen und mit den Schritten nach dem Entkopplungspunkt zur Erstellung der nachgefragten Auftragsmenge fortzufahren. Die Wiederbeschaffungszeit ist entsprechend die Zeitdauer, um das Lager am Entkopplungspunkt aufzufüllen.

Die bisherige Beschreibung des Entkopplungspunkts war von einer konkreten Wertschöpfungskette abstrahiert. Es existieren allerdings schon diverse Arbeiten, die unterschiedliche Entkopplungspunkte in einer Wertschöpfungskette beschreiben. In Abbildung 2.9 sind die drei in der Literatur am häufigsten erläuterten Entkopplungspunkte *Make-to-order* (MTO), *Assemble-to-order* (ATO) und *Make-to-stock* (MTS)¹⁵ aufgeführt. Sie werden beispielsweise von Sharman (1984), Hoekstra und Romme (1991, S. 6 ff.), Meyr (2003), Olhager (2003, 2010) sowie Vollmann u.a. (2005, S. 20 ff.) dargestellt. Diese sind in eine einfache generische Wertschöpfungskette, bestehend aus vier Schritten, eingebettet. Reale Wertschöpfungsketten sind häufig deutlich komplexer, bestehen meist aus mehr Schritten und umfassen neben den dargestellten primären auch noch unterstützende Tätigkeiten, wie von Porter (2014, S. 61–85) beschrieben. Der Prozess beginnt zunächst mit dem Einkauf der Rohstoffe und Materialien für die Produktion. Diese werden anschließend in zwei Schritten zu einem Endprodukt verarbeitet. In der Komponentenfertigung erfolgt zunächst die Herstellung von meist standardisierten Zwischenprodukten, die Teil des späteren Endprodukts sind. Diese unfertigen Zwischenprodukte werden in der folgenden finalen Fertigung bei der Erstellung des Endprodukts weiterverarbeitet. Bei der Produktion von Möbelstücken können beispielsweise zunächst Standardkomponenten wie Türen, Schubladen oder Stoffbezüge gefertigt werden. Diese werden dann bei der Erstellung des jeweiligen Endprodukts in dem Möbelstück verbaut. Die Wertschöpfungskette endet mit der Auslieferung des Produkts an den Kunden.

(2004).

¹⁵Dieser Entkopplungspunkt wird beispielsweise von Meyr und Stadtler (2008) auch als *deliver-to-order* bezeichnet.




Abbildung 2.9.: Verschiedene Entkopplungspunkte

In der Darstellung dieser Wertschöpfungskette in Abbildung 2.9 sind die drei Entkopplungspunkte MTO, ATO und MTS illustrativ eingefügt. Sie lassen sich wie folgt beschreiben:

MTO Der Entkopplungspunkt liegt in diesem Fall direkt nach dem Einkauf. Mit den eigentlichen Herstellungsschritten wird erst begonnen, wenn dafür ein Kundenauftrag vorliegt. Einzig für den Einkauf von Rohstoffen und Materialien muss kein Auftrag vorhanden sein. Dieser Entkopplungspunkt kann beispielsweise geeignet sein, wenn es Kundenanforderungen gibt, die eine Konfiguration von End- und Zwischenprodukten erforderlich macht. Die Herstellung beginnt dann erst, wenn der konkrete Auftrag mit den detaillierten Kundenanforderungen vorliegt.

ATO ATO liegt in der Wertschöpfung zwischen MTO und MTS. Der Entkopplungspunkt ist zwischen den eigentlichen Herstellungsschritten positioniert. Die finale Fertigung und anschließende Auslieferung wird nur auf Basis eines Kundenauftrags durchgeführt. Für den Einkauf von Rohstoffen und die Komponentenfertigung muss es diesen Auftrag nicht unbedingt geben. Die Komponenten werden auf Lager gefertigt und nach dem Bestelleingang hieraus für die Fertigstellung des Endprodukts genommen. ATO kann beispielsweise bei der Produktion von Endprodukten eingesetzt werden, die standardisierte Komponenten enthalten, aber gleichzeitig spezifische Kundenanforderungen berücksichtigen müssen. Die Standardkomponenten können auf Lager produziert und nach Auftragsingang in der finalen Fertigung unter Beachtung der spezifischen Kundenwünsche verarbeitet werden.

MTS Bei MTS ist der Entkopplungspunkt nach den eigentlichen Herstellungsschritten positioniert. Der einzige Schritt, der erst ausgeführt wird, wenn ein Auftrag eingegangen ist, ist die Auslieferung der Endprodukte an den Kunden. Für die Fertigstellung der Endprodukte ist das Vorliegen eines Kundenauftrags nicht notwendig. Die Endprodukte werden auf Lager produziert und nach dem Auftragsingang hieraus entsprechend ausgeliefert. MTS kann beispielsweise bei der Produktion von standardisierten Endprodukten verwendet werden, die dem Kunden keine Konfigurationsmöglichkeiten einräumen.

Zusätzlich zu den Entkopplungspunkten MTO, ATO und MTS wurden von verschiedenen Autoren einige weitere Entkopplungspunkte beschrieben. Hoekstra und Romme (1991, S. 6 ff.), Meyr (2003) sowie Fleischmann und Meyr (2004) stellen *Purchase-and-make-to-order* (PMTO) als weiteren Entkopplungspunkt vor. Der Entkopplungspunkt liegt bei PMTO noch vor dem Einkauf. Einige Rohstoffe und Materialien werden also erst nach dem Auftragseingang bestellt. Wie Meyr (2003) darstellt, kann dieser Entkopplungspunkt geeignet sein, wenn besonders teure Rohstoffe für die Produktion benötigt werden, deren Lagerhaltung hohe Kosten und Risiken implizieren würde. Diese Rohstoffe würden dann erst nach Bestellungseingang direkt für die Umsetzung des vorliegenden Auftrags bestellt werden, um eine Lagerhaltung zu vermeiden.

Mit *Engineer-to-order* (ETO) wird von Sharman (1984), Olhager (2003, 2010) sowie Vollmann u.a. (2005, S. 20 ff.) ein weiterer Entkopplungspunkt präsentiert, der noch vor PMTO in der Wertschöpfung positioniert ist.¹⁶ Ein dem Einkauf vorgelagerter Schritt ist dabei die Entwicklung bzw. das Design eines Produkts. Dieser Schritt ist in einem Durchlauf des Prozesses nur notwendig, wenn für die Erstellung des Gutes weitere Entwicklungsarbeit unumgänglich ist, beispielsweise weil es das Produkt bisher nicht gab. Bei ETO liegt der Entkopplungspunkt vor diesem Entwicklungsschritt. Mit der Entwicklungsarbeit wird also erst nach Auftragseingang begonnen. ETO kann in Situationen angewendet werden, in denen der Kunde ein auf seine Anforderungen maßgeschneidertes Produkt nachfragt. Die projektbasierte Produktion ist ein gutes Situationsbeispiel für die Anwendung von ETO. So starten beispielsweise ein Architekt und eine Baugesellschaft häufig erst mit der Entwicklung eines Gebäudes, wenn ein Auftrag dafür vorliegt. Im Maschinen- und Anlagenbau wird mit der Konstruktion erst begonnen, wenn die Bestellung mit den genauen Kundenanforderungen eingegangen ist.

Mit *Make-and-ship-to-stock* (MSTS) wird von Hoekstra und Romme (1991, S. 6 ff.) sowie Fleischmann und Meyr (2004) ein weiterer Entkopplungspunkt vorgestellt, der gegenüber PMTO und ETO am Ende der Wertschöpfungskette liegt. Die Endprodukte werden bei MSTS nach der Fertigstellung nicht direkt wie bei MTS zentral gelagert, sondern auf regionale Lagerhäuser in Kundennähe verteilt. Der Entkopplungspunkt liegt also innerhalb des letzten Schrittes in Abbildung 2.9. Der einzige Schritt, für den bei MSTS ein Auftragseingang notwendig ist, ist die Auslieferung des Produkts aus einem regionalen Lagerhaus an den Kunden.

Mit *Deliver-to-stock* (DTS) muss noch ein Extremfall eines Entkopplungspunkts erwähnt werden, der unter anderem von Meyr (2003) dargestellt wird. Nach seiner Beschreibung füllt bei DTS die Supply Chain die Lager ihrer Kunden eigenverantwortlich auf. Ein konkreter Kundenauftrag ist dafür nicht zwingend notwendig. Der Entkopplungspunkt liegt bei DTS also am Ende der Wertschöpfungskette. Es gibt keine Schritte, die nur bei Vorliegen eines Kundenauftrags durchgeführt werden. Eine solche Situation, in der die Supply Chain den Lagerbestand des Kunden auf Grundlage einer Vereinbarung kontrolliert und anpasst, wird auch als *Vendor Managed Inventory* (VMI) bezeichnet. Sie wird unter anderem von Mason-Jones und Towill (1999), Meyr (2003) sowie Meyr und Stadtler (2008) beschrieben.

¹⁶Sharman (1984) nennt diesen Entkopplungspunkt *Design-and-make-to-order*.

Prinzip des Postponements

Im Zusammenhang mit dem Entkopplungspunktkonzept ist das Prinzip des *Postponements* von großer Bedeutung und sollte deshalb hier erwähnt werden. Dieses Prinzip wurde ursprünglich von Alderson (1950) vorgestellt.¹⁷ Er beschreibt das Prinzip des Postponements für einen Wertschöpfungsprozess in einer Supply Chain, der darauf ausgerichtet ist, einem Kunden ein Produkt bereitzustellen. Das Produkt wird dabei mit jedem Prozessschritt zunehmend auf spezifische Kundenanforderungen zugeschnitten, deren Erfüllung gleichzeitig die Voraussetzung für seinen Erwerb ist. Der Prozess beginnt mit der Bestellung und Verarbeitung der Rohstoffe und endet mit der Fertigstellung und Auslieferung eines spezifischen Produkts, das den Kundenanforderungen entspricht. In den Zwischenschritten wird das Produkt entsprechend den Kundenanforderungen zunehmend differenzierter. Da sich die Anforderungen verschiedener Kunden unterscheiden, führt die zunehmende Differenzierung des Produkts auch dazu, dass es den Anforderungen einer steigenden Kundenzahl widerspricht und einen Kauf durch sie ausschließt.

Bucklin (1965) schreibt, dass eine solche Differenzierung in zwei wesentlichen Dimensionen stattfinden kann. Einmal kann das Produkt selbst in seiner Beschaffenheit verändert werden. Ein einfaches Beispiel betrifft die unterschiedlichen Farbvarianten, in denen ein Produkt angeboten wird. Das Färben eines Produkts wäre eine solche Differenzierung. Die andere Form der Differenzierung betrifft die geographische Verbreitung der Produkte, wie Bucklin (1965) erläutert. So wird ein Produkt durch den Transport in eine Region differenziert und der potentielle Kundenkreis eingeschränkt. Alderson (1950) hat diesen Sachverhalt bereits beispielhaft an einem Konsumgut verdeutlicht. Es ist die Anforderung der meisten Kunden, ein Konsumgut in einem Ladengeschäft in ihrer unmittelbaren Umgebung zu erwerben. Durch den Transport des Produkts in diese Region wird diese Anforderung erfüllt. Gleichzeitig wird durch diese Differenzierung der Kreis möglicher Kunden auf Personen reduziert, die in dieser Gegend in ein Ladengeschäft gehen würden. Klarheit über die genauen Kundenanforderungen gibt es aber erst, wenn eine konkrete Bestellung vorliegt. Entscheidungen zu Produktdifferenzierungen, die ohne Vorliegen einer Bestellung vorgenommen werden, stützen sich also zwangsläufig auf Prognosen der Nachfragemenge unterschiedlicher Produktvarianten, die die Kundenanforderungen erfüllen sollen. Wie Bucklin (1965) feststellt, besteht bei einer solchen Entscheidung das Unsicherheitsrisiko, dass die vorhergesagte nicht der tatsächlich nachgefragten Menge entspricht. Eine solche Abweichung von Prognose und tatsächlicher Nachfragemenge würde in einer Entscheidung resultieren, in der die erstellten Mengen verschiedener Produktvarianten nicht den benötigten Mengen zur Erfüllung der Nachfrage entsprechen.

Nach dem von Alderson (1950) vorgestellten Prinzip des Postponements wird jeder Prozessschritt zeitlich so weit nach hinten verschoben, dass er zum spätest möglichen Zeitpunkt durchgeführt wird. Das Postponement bewirkt, dass ein Produkt möglichst so lange undifferenziert und unspezifisch bleibt, bis die Nachfrage nach den verschiedenen Varianten genauer bekannt ist. Es wird dabei davon ausgegangen, dass diese Mengen immer genauer prognostizierbar werden, je näher der Zeitpunkt der Nachfrage kommt. Die Differenzierungsentscheidung wird durch das Postponement also mit einem verminderten

¹⁷Nachdrucke dieser Arbeit finden sich bei Alderson (1957, S. 423–427) und Alderson (2006).

Risiko bezüglich der tatsächlichen Nachfrage getroffen.

Wenn dem Prinzip des Postponements keine Grenzen gesetzt wären, würden alle Differenzierungsschritte soweit verschoben werden, bis eine Bestellung vorliegt und die Kundenanforderungen damit genau bekannt sind. Das Prinzip des Postponements ist dabei vollständig auf die Herstellungsseite eines Produkts fokussiert. Erwartungen der Nachfrageseite bezüglich der Lieferzeit werden von dem Prinzip ignoriert, wie bereits Bucklin (1965) erkannte. Allerdings sind es diese Erwartungen, die die Grenzen für das Postponement setzen. Der Kunde hat einen Wunschliefertzeitpunkt für ein Produkt. Die Differenz zwischen dem Zeitpunkt des Bestellungseingangs und diesem Wunschliefertzeitpunkt entspricht der Vorlaufzeit der Bestellung. Um am Markt langfristig erfolgreich agieren zu können, darf die Lieferzeit für das Produkt diese Vorlaufzeit nicht überschreiten, weil sonst der resultierende tatsächliche Lieferzeitpunkt die Kundenerwartungen nicht erfüllen würde. Wie zuvor beschrieben, entspricht die Lieferzeit der Zeitdauer, die notwendig ist, um die Schritte in der Wertschöpfungskette nach dem Entkopplungspunkt durchzuführen. Wie von Hoekstra und Romme (1991, S. 122 ff.) oder Kilger (2008) erläutert, die diesen Zusammenhang bereits erkannten, können deshalb nur die Schritte nach dem Entkopplungspunkt positioniert werden, die in einer Lieferzeit resultieren, die eine Auslieferung zum Wunschliefertzeitpunkt ermöglicht. Die Kundenerwartungen an die Lieferzeit beschränken so das Postponement von Schritten in der Wertschöpfungskette.

Konsumgüter sind bezüglich der Vorlaufzeit und erwarteten Lieferzeit ein Extrembeispiel. Der Kunde will ein solches Produkt üblicherweise direkt aus dem Regal in einem Ladengeschäft kaufen. Es gibt also so gut wie keine Vorlaufzeit für diesen Kauf. Entsprechend wird es selten möglich sein, differenzierende Fertigungsschritte in der Wertschöpfungskette auf Grundlage einer konkreten Bestellung durchzuführen.

Trotz dieser Einschränkungen des Postponements hat das Prinzip großen Einfluss auf die Ausgestaltung der Wertschöpfungskette. Dabei gilt es, das von Lee und Tang (1997) vorgestellte Konzept des *Point of Differentiation* miteinzubeziehen. Lee und Tang (1997) definieren diesen Punkt als Stelle in der Wertschöpfung, an der aus relativ unspezifischen Zwischenprodukten durch Differenzierung ein relativ eindeutiges Endprodukt wird. Diese nicht ganz trennscharfe Definition kann am Beispiel des Buchdrucks verdeutlicht werden. Ein Verlag bestellt Papier und Druckerfarbe als Materialien für seine Produktion. Beide Materialien sind relativ generische und unspezifische Produkte. Sie können für den Druck diverser Bücher eingesetzt werden. Erst durch den eigentlichen Druck wird aus diesen Zwischenprodukten ein spezifisches Buch als Endprodukt. Die von Meyr (2003) präsentierte Definition des Point of Differentiation erscheint für die folgende Darstellung etwas geeigneter. Er beschreibt den Point of Differentiation als Stelle in der Wertschöpfungskette, an der aus einigen generischen Komponenten eine größere Zahl von Folgeprodukten wird. Das Beispiel des Buchdrucks ist auf diese Form der Definition ebenfalls anwendbar. Sie ist allerdings insofern etwas allgemeiner gehalten, als dass sie nicht auf Stellen beschränkt ist, an denen durch die Differenzierung ein eindeutiges Endprodukt entsteht. Das folgende Beispiel verdeutlicht den Unterschied zwischen den Definitionen. Ein Möbelhersteller erhält als Materialien für seine Fertigung eine bestimmte Holzart. Dieses Material wird in einem ersten Schritt auf die notwendigen Maße zugeschnitten. Je nach Schnitt kann dieses Zwischenprodukt beispielsweise als Außenwand eines Schrankes,

Bein eines Tisches oder Lehne eines Stuhls verwendet werden. Da es diverse Zwischenprodukte gibt, ist der Zuschnitt ein Point of Differentiation. Allerdings ist damit noch nicht das eindeutige Endprodukt für dieses Zwischenprodukt festgelegt. Es kann diverse Schrankmodelle geben, die dieselben Abmessungen für die Außenwände haben. Die Zwischenprodukte könnten außerdem mit den unterschiedlichsten Farben bearbeitet werden. Das finale Endprodukt für das Zwischenprodukt steht nach diesem Point of Differentiation also noch nicht fest. Trotzdem wird durch die Differenzierung an dieser Stelle das Produkt viel spezifischer und seine Anwendungsmöglichkeiten für verschiedene Produktvarianten deutlich beschränkt.

Lee und Tang (1997) kamen zu dem Schluss, dass ein Point of Differentiation möglichst spät in der Wertschöpfung liegen sollte. Meyr (2003) hebt hervor, dass der Entkopplungspunkt und der Point of Differentiation als Stellen in einer Wertschöpfungskette unterschieden werden müssen. Beide Punkte können an der gleichen Stelle liegen, müssen dies aber nicht. Weiter führt er aus, dass der Point of Differentiation möglichst nicht vor dem Entkopplungspunkt liegen sollte. Andernfalls müssten sämtliche Produktvarianten, die nach dem Point of Differentiation in der Wertschöpfung vorliegen, in der Lagerhaltung am Entkopplungspunkt berücksichtigt werden. Dies würde die Komplexität und Kosten der Lagerhaltung deutlich steigern. Es ist einfacher und meistens kostengünstiger, die deutlich geringere Zahl unspezifischer Zwischenprodukte vor dem Point of Differentiation zu lagern, als sämtliche Produktvarianten, die es danach gibt, weil die insgesamt benötigten Sicherheitsbestände dann deutlich geringer sind.

Die Bedeutung des Entkopplungspunktkonzepts für das Supply Chain Management wird im folgenden Abschnitt erläutert.

2.4. Bedeutung des Entkopplungspunktkonzepts für das Supply Chain Management

Das Entkopplungspunktkonzept ist vor allem für das Strategic Network Design und diverse operative Planungsmodule relevant. Je nach Position des Entkopplungspunkts werden verschiedene Schritte in der Wertschöpfung kurzfristig auf Basis von Kundenaufträgen oder Prognosen geplant und durchgeführt. Eine detaillierte Erläuterung der Bedeutung des Entkopplungspunkts für die verschiedenen operativen Planungsmodule erfolgt in Abschnitt 2.4.1. Dabei wird auch die Relevanz eines sukzessiven Bestellungseingangs für das Entkopplungspunktkonzept und die operative Planung hervorgehoben. In diesem Zusammenhang spielen die Ergebnisse der Arbeit von Meyr (2003) eine wesentliche Rolle. Das von ihm eingeführte Auftragsprofil wird in diesem Abschnitt detailliert beschrieben und gewürdigt. Es ist eine wichtige Grundlage für die folgenden Analysen und Untersuchungen in dieser Arbeit.

Neben der kurzfristigen Planung und Steuerung der Supply Chain für einen gegebenen Entkopplungspunkt ist dessen optimale Positionierung eine langfristige Fragestellung für das Strategic Network Design. Eine notwendige Repositionierung, weil sich beispielsweise Kundenerwartungen oder technische Voraussetzungen verändert haben, ist in diesem Planungsmodul zu untersuchen und bestimmen, wie in Abschnitt 2.4.2 dargestellt wird.

Die Bedeutung der Untersuchungsergebnisse dieser Arbeit für das Entkopplungspunktkonzept und damit auch für die verschiedenen Planungsmodule wird in den beiden folgenden Abschnitten an entsprechender Stelle aufgegriffen.

2.4.1. Einfluss des Entkopplungspunkts auf die operative Planung

Um den Einfluss des Entkopplungspunkts auf die verschiedenen Planungsmodule zu verdeutlichen, hat Vogel (2014, S. 40) die Supply Chain Planning-Matrix von Fleischmann u.a. (2008) erweitert, wie in Abbildung 2.10 dargestellt. Je nach Position des Entkopplungspunkts sind es unterschiedliche Aufgaben aus der operativen Planung, die erst auf Grundlage vorliegender Kundenbestellungen geplant und durchgeführt werden. Bei MTS sind dies vor allem Aufgaben aus der kurzfristigen Distributions- und Absatzplanung. Je weiter der Entkopplungspunkt upstream in der Wertschöpfung positioniert ist, desto mehr Aktivitäten aus den korrespondierenden Planungsmodulen werden erst begonnen, wenn eine Kundenbestellung dafür vorliegt. Bei MTO kann dies dann sogar einige Planungsaufgaben aus der Beschaffung betreffen, wie Vogel (2014, S. 37–42) erläutert.




Abbildung 2.10.: Einfluss des Entkopplungspunkts auf Supply Chain Planning-Matrix nach Vogel (2014, S. 40)

Die Durchführung der Schritte vor dem Entkopplungspunkt ist durch Prognosen getrieben, die die zukünftige Nachfrage antizipieren. Die Aktivitäten nach dem Entkopplungspunkt beginnen als Reaktion auf eine eingegangene Bestellung. Einige Autoren¹⁸, die diesen Zusammenhang bereits beschrieben haben, bezeichnen die Schritte vor dem

¹⁸Vgl. bspw. Meyr (2003), Fleischmann und Meyr (2004), Kilger und Meyr (2008) oder Vogel (2014, S. 37–42).

Entkopplungspunkt entsprechend als antizipativ und die danach als reaktiv.

Eine detailliertere Untersuchung unterschiedlicher Charakteristika, die die Vorgehensweisen bei Fertigungsschritten vor und nach dem Entkopplungspunkt aufweisen, wird von Olhager (2003, 2010) präsentiert. Er beschreibt die Fertigung vor dem Entkopplungspunkt als eine, die auf Effizienz und niedrige Kosten ausgelegt ist. Häufig werden in diesen Schritten nach Olhager (2003, 2010) große Mengen von Standardkomponenten hergestellt, wobei eine möglichst hohe Auslastung der vorhandenen Produktionsressourcen angestrebt wird. Die Schritte nach dem Entkopplungspunkt sind nach Olhager (2003, 2010) oft darauf fokussiert, schnell und flexibel auf die Marktbedürfnisse reagieren zu können. Aufgabe dieser Schritte ist es, die Produkte auf die Kundenanforderungen zuzuschneiden und mit der erwarteten Lieferzeit bereitzustellen.

Meyr (2003) hat die Bedeutung unterschiedlicher Entkopplungspunkte für die operativen Planungsmodule untersucht. Konkret beschreibt er den Einfluss unterschiedlicher Entkopplungspunkte für das Demand Planning, Demand Fulfillment, Master Planning, Production Planning und Scheduling sowie das Distribution und Transport Planning. So werden beispielsweise in einer MTO-Situation beim Scheduling die vorliegenden Kundenaufträge betrachtet und in der Erstellung einer Reihenfolge für die Fertigung berücksichtigt. Dies geschieht nicht bei MTS, weil die Aufträge dafür gar nicht vorliegen.

Eine besonders zentrale Rolle spielt der Entkopplungspunkt für das Demand Fulfillment. Er ist für die Planungsaufgaben im Order Promising und Fulfillment von großer Bedeutung, wie bereits Fleischmann und Meyr (2004) erkannten. Die von Kilger und Meyr (2008) beschriebene Kalkulation eines versprochenen Liefertermins im Order Promising unterscheidet sich für verschiedene Entkopplungspunkte beispielsweise stark. Da der Entkopplungspunkt maßgeblich ist für die noch durchzuführenden Wertschöpfungsschritte, hat er damit auch direkten Einfluss auf die mögliche Lieferzeit und die Verfahren zu dessen Berechnung. Ähnlich ist es im Order Fulfillment, das die Ausführung aller Aktivitäten nach dem Entkopplungspunkt plant und steuert, wie bereits Fleischmann und Meyr (2004) erläuterten. Der Umfang an Aktivitäten, den das Order Fulfillment berücksichtigen muss, unterscheidet sich dabei für unterschiedliche Entkopplungspunkte klar. Während der Fokus in einer MTS-Situation auf der Planung und Steuerung der Auslieferung liegt, sind bei MTO oder ATO noch diverse Produktionsschritte zu beachten.

Bedeutung eines sukzessiven Bestellungseingangs für den Entkopplungspunkt

Der Entkopplungspunkt hat also großen Einfluss auf die Ausgestaltung und Durchführung diverser operativer Planungsaufgaben in einer Supply Chain. Ein wesentlicher Aspekt, der vom Entkopplungspunktkonzept in der bisher beschriebenen Form nicht beachtet wurde, ist der sukzessive Eingang von Bestellungen. Meyr (2003) hat diesen Aspekt bereits in seiner Arbeit analysiert. Seine Ergebnisse werden hier nun kurz vorgestellt.

Das klassische Konzept des Entkopplungspunkts beschreibt diesen als fixe Stelle in der Wertschöpfungskette einer Supply Chain. Wenn eine Aktivität nach dieser Stelle liegt, wird sie immer auf Grundlage einer vorliegenden Bestellung durchgeführt. Aktivitäten, die hingegen vor dem Entkopplungspunkt positioniert sind, werden nach der bisherigen Definition auf Basis von Prognosen geplant und gesteuert. Wie Meyr (2003) zeigt, exis-

tieren einige Situationen in der Realität¹⁹, die durch diese Definition nicht abgebildet werden können.

Der Abschluss eines Rahmenvertrags ist ein Beispiel für eine solche Situation, wie von Meyr (2003) beschrieben. In einem solchen Vertrag kann sich ein Kunde beispielsweise verpflichten, eine gewisse Menge eines bestimmten Produkts innerhalb eines festgesetzten Zeitrahmens abzunehmen. Im Gegenzug erhält er meistens dafür verbesserte Konditionen. Bis auf den exakten Wunschlieferzeitpunkt ist die Kundenbestellung durch diesen Rahmenvertrag vollkommen spezifiziert. Wenn sich die Planung und Steuerung eines Schrittes nun an diesen Rahmenverträgen orientiert, ist nicht eindeutig zu klären, ob der Entkopplungspunkt vor oder hinter diesem Schritt liegt.

Meyr (2003) stellt noch eine weitere Situation dar, in der es schwierig ist, den Entkopplungspunkt eindeutig zu bestimmen. In dieser basiert die Durchführung einer Aktivität teilweise auf vorliegenden Bestellungen und teilweise auf Prognosen. Er beschreibt dafür eine Wertschöpfungskette, aus der mehrere unterschiedliche Endprodukte hervorgehen.²⁰ Es wird dabei eine Aktivität dieses Prozesses betrachtet, aus der ein Zwischenprodukt hervorgeht, das in diversen Endprodukten verarbeitet wird. Für einige Endprodukte liegen schon Bestellungen vor, wenn das Zwischenprodukt erstellt wird, für andere existieren nur Prognosen der zukünftigen Nachfrage. Um die zu fertigende Menge an Zwischenprodukten zu bestimmen, werden also sowohl vorliegende Aufträge als auch Prognosen benutzt. Meyr (2003) beschreibt, dass in dieser Situation der Entkopplungspunkt nicht eindeutig ermittelt werden kann.

Die Problematik liegt in der bisherigen Definition des Entkopplungspunkts. In ihr wird davon ausgegangen, dass Aktivitäten vor dem Entkopplungspunkt immer vollständig auf Grundlage von Prognosen und Aktivitäten danach immer vollständig auf Grundlage vorliegender Bestellungen durchgeführt werden. Diese Annahme ist nicht realistisch, wie die beiden Beispiele und die folgende Darstellung der daraus resultierenden Implikationen zum Bestellverhalten verdeutlichen.

Wenn der Entkopplungspunkt eine eindeutige und fixe Position hat, dann ist es möglich, sämtliche Aktivitäten in der Wertschöpfungskette entweder klar vor oder nach dieser Stelle zu positionieren. Werden nur die Aktivitäten nach dem Entkopplungspunkt betrachtet, dann kann eindeutig die Durchlaufzeit bestimmt werden, die für deren Durchführung benötigt wird. Da die Aktivitäten nach dem Entkopplungspunkt immer dieselben sind, kann nun aus diesen Durchlaufzeiten die konstante Lieferzeit für eine Bestellung abgeleitet werden.

Wie bereits Meyr (2003) ausführt, impliziert dies gleichzeitig, dass sämtliche Bestellungen mit der gleichen Vorlaufzeit eingehen. Diese Vorlaufzeit entspricht dabei genau der konstanten Lieferzeit, die aus den Durchlaufzeiten der Aktivitäten nach dem Entkopplungspunkt resultiert. Eine Bestellung kann nicht mit einer längeren Vorlaufzeit eingehen,

¹⁹Meyr (2003) bezeichnet sie als Übergangs- und Mischformen.

²⁰Meyr und Stadtler (2008) nennen einige Hersteller von Konsumgütern als Beispiel für eine Supply Chain mit einer solchen Wertschöpfungskette. Ein Hersteller von Limonade kann beispielsweise dasselbe Getränk in verschiedenen Verpackungen und unter unterschiedlichen Markennamen vertreiben. Die diversen verkauften Varianten dieses Getränks stellen verschiedene Endprodukte dar. Aus der Wertschöpfungskette zur Herstellung der Getränke resultieren also mehrere Endprodukte.

weil sie sonst bereits für die Planung und Steuerung der Aktivitäten vor dem Entkopplungspunkt zur Verfügung steht. Eine kürzere Vorlaufzeit ist auch nicht möglich, da die Bestellungen für sämtliche Aktivitäten nach dem Entkopplungspunkt vorliegen müssen. Abbildung 2.11 von Meyr (2003) zeigt das implizierte Bestellverhalten in einer zeitlich kontinuierlichen Betrachtung. Dargestellt ist der Anteil der tatsächlichen Nachfrage, der durchschnittlich zu unterschiedlichen Vorlaufzeiten in Form von Bestellungen vorliegt. Dieser durchschnittliche Anteil beträgt 0% vor und 100% nach dem Entkopplungspunkt, da sämtliche Bestellungen mit der gleichen Vorlaufzeit eingehen.




Abbildung 2.11.: Bestellverhalten beim klassischen Entkopplungspunktkonzept

Ein solches Bestellverhalten ist natürlich unrealistisch. Wie Meyr (2003) schreibt und wie die in Kapitel 5 untersuchten Praxisdatensätze zeigen, gehen die Bestellungen sukzessive mit unterschiedlichen Vorlaufzeiten und Wunschlieferzeitpunkten ein. Der zeitliche Verlauf des durchschnittlich in Bestellungen vorliegenden Nachfrageanteils entspricht eher einer Normalverteilungsfunktion. In Abbildung 2.12 ist ein solches Kundenverhalten exemplarisch illustriert. Die beiden Vorlaufzeiten e_1 und e_2 sind beispielhaft markiert. Ex-post betrachtet, sind mit einer Vorlaufzeit von e_1 zum Wunschlieferzeitpunkt²¹ durchschnittlich 20% der Nachfragemenge bereits bestellt. Analog sind dies bei einer Vorlaufzeit von e_2 60% der Nachfragemenge.

Der Zusammenhang zwischen dem Bestellungseingang und dem Entkopplungspunkt wurde auch von Vollmann u.a. (1992, S. 317 ff.) sowie Vollmann u.a. (2005, S. 17 ff.) untersucht. Sie beschreiben, wie durch den sukzessiven Bestellungseingang der bekannte Anteil der Nachfrage kontinuierlich steigt, wenn der Lieferzeitpunkt näher rückt. Eingehende Bestellungen füllen zunehmend die prognostizierte Nachfragemenge aus und senken rückblickend den Anteil der Nachfrage, für den eine Vorhersage notwendig ist. So kann

²¹Wie bereits bei den Ausführungen zum Postponement erwähnt, muss dabei langfristig der Wunschlieferzeitpunkt dem tatsächlichen Lieferzeitpunkt entsprechen, um erfolgreich am Markt zu bestehen.




Abbildung 2.12.: Beispiel für sukzessives Bestellverhalten

für das Beispiel in Abbildung 2.12 ex-post festgehalten werden, dass bei einer Vorlaufzeit von e_1 durchschnittlich 20% der Nachfrage bekannt waren und ausschließlich die verbleibenden 80% prognostiziert werden mussten.

Weiter beschreiben Vollmann u.a. (1992, S. 317 ff.) sowie Vollmann u.a. (2005, S. 17 ff.) das typische Bestellverhalten für die drei am stärksten verbreiteten Entkopplungspunkte MTO, ATO und MTS. In Abbildung 2.13 ist das Bestellverhalten für diese drei Entkopplungspunkte illustriert. Bei MTS werden die eingehenden Bestellungen direkt aus einem Lager mit Endprodukten bedient. Die Kunden erwarten eine entsprechend kurzfristige Auslieferung, weshalb die Bestellungen in diesem Fall die Supply Chain mit der geringsten Vorlaufzeit erreichen. Je weiter upstream in der Wertschöpfungskette der Entkopplungspunkt positioniert ist, desto mehr Schritte sind vor einer Auslieferung der Bestellung durchzuführen. Kunden, die diesen Entkopplungspunkt mit der daraus resultierenden Lieferzeit akzeptieren, geben ihre Bestellungen entsprechend mit einer längeren Vorlaufzeit ab, um die Produkte rechtzeitig zu erhalten. Der langfristigste Bestellungseingang ist deshalb, wie in Abbildung 2.13 dargestellt, in einer MTO-Situation zu erwarten.

Meyr (2003) kritisiert die mangelnde Berücksichtigung des sukzessiven Bestellungseingangs im klassischen Entkopplungspunktkonzept. Er entwirft deshalb das *Auftragsprofil*, um den Einfluss des Bestellverhaltens auf den Entkopplungspunkt ex-post abzubilden.

Auftragsprofil von Meyr (2003)

Das Auftragsprofil von Meyr (2003) erlaubt es, die ADI strukturiert zu erfassen und das durchschnittliche Bestellverhalten rückblickend zu beschreiben. Es dient als übersichtliche Grundlage, um die Bedeutung des Bestellverhaltens und eines sukzessiven Auftrags-eingangs für das Entkopplungspunktkonzept darzustellen und mögliche Implikationen für die operative Planung zu identifizieren. Meyr (2003) definiert für das Auftragsprofil




Abbildung 2.13.: Bestellverhalten für unterschiedliche Entkopplungspunkte nach Vollmann u.a. (1992, S. 317 ff.) und Vollmann u.a. (2005, S. 17 ff.)

mehrere Variablen.²² Es ist hervorzuheben, dass diesen Variablen wieder diskrete Zeitabschnitte zugrunde liegen. Die in der folgenden Definition betrachteten Zeitpunkte s und t entsprechen beispielsweise solchen diskreten Zeitabschnitten. Als erstes wird folgende Variable zur Erfassung der Auftragsmenge definiert:

D_{ts} Insgesamt bis zum Zeitpunkt t eingegangene Bestellmenge mit Wunschlieferszeitpunkt s

Die Variable entspricht der Nachfrage für den Wunschlieferszeitpunkt s , die der Supply Chain in Bestellungen bis zum Zeitpunkt t vorliegt. Die Variable D_{ss} repräsentiert die tatsächliche Nachfrage für den Wunschlieferszeitpunkt s . Die Vorlaufzeit sämtlicher Bestellungen in D_{ts} beträgt dabei mindestens $e = s - t$. Um den prozentualen Anteil der eingegangenen Bestellmenge an der tatsächlichen Nachfrage zu beschreiben, wird von Meyr (2003) folgende Variable verwendet:

X_{es} Prozentualer Anteil der Bestellmenge $D_{(s-e)s}$ an der tatsächlichen Nachfragemenge D_{ss}

Es gilt $X_{es} = D_{(s-e)s} / D_{ss}$. Um das durchschnittliche Bestellverhalten zu bewerten, berechnet Meyr (2003) für eine beliebige Vorlaufzeit $e \geq 0$ das arithmetische Mittel $\mu(X_e)$,

²²Die Bezeichnungen für die Variablen unterscheiden sich in diesem Abschnitt von denen, die Meyr (2003) verwendet. Sie sind an die Bezeichnungen in dieser Arbeit angepasst. Die Bedeutungen sind aber identisch.

die Varianz $\sigma^2(X_e)$ sowie die Standardabweichung $\sigma(X_e)$ der Variablen X_{es} über mehrere Wunschlieferszeitpunkte s . Die Werte können mit den bekannten Formeln aus der Statistik²³ ermittelt werden.

Ein Einsatz des Auftragsprofils wird exemplarisch entlang der Beispieldaten in Tabelle 2.2 dargestellt. Der obere Teil der Tabelle enthält die Nachfragemenge für die Wunschlieferszeitpunkte 1 bis 6. So sind beispielsweise für den Wunschlieferszeitpunkt 5 bis zum Zeitpunkt 4 Bestellungen mit einer Menge von $D_{45} = 75$ eingegangen. Der Wert ist in der Tabelle entsprechend fett markiert. Im unteren Tabellenteil sind die prozentualen Anteile der Bestellmengen an der tatsächlichen Nachfrage aufgeführt. Für die bereits vorher herausgegriffene Bestellmenge für den Wunschlieferszeitpunkt 5, die mit einer Vorlaufzeit von mindestens 1 vorgelegen hat, gilt entsprechend $X_{15}=75\%$.

D_{ts}	<i>Wunschlieferszeitpunkt</i>					
	$s = 1$	$s = 2$	$s = 3$	$s = 4$	$s = 5$	$s = 6$
$t = 1$	100	80	50	20	5	0
$t = 2$		120	90	45	30	10
$t = 3$			130	80	45	20
$t = 4$				110	75	40
$t = 5$					100	80
$t = 6$						100
X_{es}	$s = 1$	$s = 2$	$s = 3$	$s = 4$	$s = 5$	$s = 6$
$t = 1$	100%	67%	38%	18%	5%	0
$t = 2$		100%	69%	41%	30%	10%
$t = 3$			100%	73%	45%	20%
$t = 4$				100%	75%	40%
$t = 5$					100%	80%
$t = 6$						100%

Tabelle 2.2.: Anwendungsbeispiel für das Auftragsprofil von Meyr (2003)

In Tabelle 2.3 sind das arithmetische Mittel, die Varianz und die Standardabweichung für Vorlaufzeiten zwischen 0 und 4 zu dem Anwendungsbeispiel aus Tabelle 2.2 aufgeführt. Das arithmetische Mittel für eine Vorlaufzeit von $e = 2$ wurde beispielsweise mit der bekannten Formel aus der Statistik wie folgt berechnet:

$$\mu(X_2) = \frac{1}{4} \cdot (38\% + 41\% + 45\% + 40\%) \approx 41\%$$

Wie Meyr (2003) weiter ausführt, kann exponentielle Glättung verwendet werden, um die Werte mit Voranschreiten der Zeit zu aktualisieren. In dem Beispiel wäre damit die Aktualisierung der Durchschnittswerte gemeint, wenn der Wunschzeitlieferzeitpunkt 7 erreicht ist und dafür neue Bestellinformationen vorliegen. Die exponentielle Glättung wird in dieser Arbeit in Kapitel 4 noch detailliert beschrieben und deshalb nicht an dieser Stelle erläutert.

²³Vgl. bspw. Bley Müller u.a. (2002, S.13 ff.).

	<i>Vorlaufzeit der Bestellungen</i>				
	$e = 0$	$e = 1$	$e = 2$	$e = 3$	$e = 4$
$\mu(X_e)$	100%	73%	41%	23%	8%
$\sigma^2(X_e)$	0	0,27%	0,08%	0,40%	0,13%
$\sigma(X_e)$	0	5%	3%	6%	4%

Tabelle 2.3.: Durchschnittliches Bestellverhalten in dem Anwendungsbeispiel aus Tabelle 2.2

Das Auftragsprofil ermöglicht es, den sukzessiven Bestellungseingang zu erfassen, zu analysieren und zu bewerten. Die Einbindung dieser Informationen kann insbesondere für die operative Planung von großer Bedeutung sein. Anstatt eine Aktivität wie in der bisherigen Definition des Entkopplungspunkts entweder nur auf Grundlage von Bestellungen oder Prognosen zu planen und durchzuführen, ist es nun gegebenenfalls möglich, vorliegende Bestellungen und Prognosen für ein optimiertes Vorgehen zu kombinieren. Der Vorteil dieses Vorgehens kann am Demand Planning verdeutlicht werden, wie bereits von Meyr (2003) beschrieben. Eine wesentliche Aufgabe des Demand Plannings ist es, die zukünftige Nachfrage zu prognostizieren. Natürlich sind solche Vorhersagen selten exakt und der tatsächliche Bedarf weicht meistens von der Prognose ab. Um diese Nachfrageunsicherheit zu kompensieren und Abweichungen in der Planung abfedern zu können, ist die Haltung von Sicherheitsbeständen notwendig. Wie Kilger und Wagner (2008) schreiben, orientiert sich die Größe dieser Sicherheitsbestände an der Stärke der Bedarfsabweichungen von der Prognose. Kann durch die Einbeziehung vorliegender Bestellungen die mit den Prognosen verbundene Unsicherheit in der Planung reduziert werden, hat dies einen direkten Einfluss auf die notwendigen Sicherheitsbestände für die Supply Chain.

Bedeutung der untersuchten Fragestellungen in dieser Arbeit

Zielsetzung der Arbeit ist es, ein Vorgehen zu beschreiben, das es ex-post erlaubt, den Entkopplungspunkt in der Wertschöpfungskette einer Supply Chain objektiv zu messen und zu bewerten. Ein solches Vorgehen wurde bisher nicht entwickelt. Diese Lücke sucht diese Arbeit nun mit den Ausführungen in Kapitel 6 zu schließen. Ein Großteil der vorhandenen Literatur fokussiert sich auf die Positionierung des Entkopplungspunkts in einer Wertschöpfungskette. Diese Aufgabe ist Teil des Strategic Network Designs und wird im nächsten Abschnitt vorgestellt. Keine dieser Arbeiten bietet allerdings die Methoden, die rückblickend eine Analyse erlauben, ob dieser Entkopplungspunkt auch tatsächlich so verwendet wird.

Eine wichtige Grundlage für diese ex-post Identifizierung des Entkopplungspunkts ist die ADI und das damit verbundene durchschnittliche Bestellverhalten, das durch das Auftragsprofil von Meyr (2003) erfasst wird. Dieses Auftragsprofil berücksichtigt allerdings wichtige Aspekte des Bestellverhaltens und des Entkopplungspunktkonzepts bisher nicht. Eine explizite Differenzierung verschiedener Kunden, Produkte und Bestelleingangsstellen erlaubt das Auftragsprofil von Meyr (2003) nicht. Diese Punkte können allerdings von großer Bedeutung sowohl für das Bestellverhalten als auch den Entkopplungspunkt sein. So können unterschiedliche Kunden verschiedene Bestellgewohnheiten

aufweisen, und mit verschiedenen Produkten können unterschiedliche Wertschöpfungsketten verbunden sein. Um diese Aspekte in der Analyse zu beachten, wird in Kapitel 3 das *verallgemeinerte Auftragsprofil* als Weiterentwicklung des Auftragsprofils von Meyr (2003) vorgestellt.

Das verallgemeinerte Auftragsprofil beschreibt allerdings ausschließlich das Bestellverhalten und die damit verbundenen Wunschlieferzeiten. Es betrachtet so nur die Marktanforderungen und ignoriert die Supply Chain mit ihrer Wertschöpfungskette vollkommen. Für die Bestimmung des Entkopplungspunkts ist es allerdings wichtig, genau diese Wertschöpfungskette zu analysieren. Es müssen die Durchlaufzeiten der einzelnen Wertschöpfungsschritte, die der Zeitdauer für deren Durchführung entsprechen, sowie die tatsächlichen Lieferzeiten ermittelt und in die Untersuchung miteinbezogen werden. In Kapitel 6 werden die für die Analyse notwendigen Messwerte klar definiert und beschrieben. Die Zusammenhänge zwischen den verschiedenen Messwerten werden anschließend untersucht und es wird beschrieben, wie ex-post der Entkopplungspunkt ermittelt werden kann. Eine Überprüfung der Entkopplungspunktposition, die den beschriebenen großen Einfluss auf die operative Planung hat, ist so erstmals möglich. Die Analyse ist auch eine wichtige Grundlage für die Identifikation von Schwachstellen und Optimierungspotenzialen in der aktuellen Wertschöpfungskette sowie für eine mögliche Repositionierung des Entkopplungspunkts im Rahmen des Strategic Network Designs.

2.4.2. Einfluss des Entkopplungspunkts auf das Strategic Network Design

Der Entkopplungspunkt hat, wie beschrieben, großen Einfluss auf die Wertschöpfungskette und viele operative Aktivitäten einer Supply Chain. Eine Veränderung seiner Position ist aufwendig und weder kurz- noch mittelfristig möglich. Wie bereits Meyr (2003) feststellte, ist die Veränderung des Entkopplungspunkts eine langfristige strategische Aufgabe, die damit Teil des Strategic Network Designs ist.

Es wurden bereits zahlreiche Arbeiten veröffentlicht, die die Thematik der optimalen Entkopplungspunktposition untersuchen.²⁴ Es wurden dabei diverse Einflussfaktoren identifiziert, die eine Position des Entkopplungspunkts weiter downstream oder upstream in der Wertschöpfungskette begünstigen. Es wird nun ein kurzer Überblick zu diesen Einflussfaktoren gegeben und die Bedeutung der Untersuchungsergebnisse dieser Arbeit für die Optimierung der Entkopplungspunktposition beschrieben.

Zusätzlich muss erwähnt werden, dass es einige Arbeiten gibt, die den Entkopplungspunkt in einem bestimmten Industriezweig untersuchen. Sie beschreiben Besonderheiten, die für die Entkopplungspunktposition in den verschiedenen Situationen relevant sind.²⁵ Da diese Arbeit allerdings keine spezifische Untersuchung für eine solche Situation enthält, werden sie hier nicht detailliert aufgegriffen.

²⁴Vgl. beispielsweise Hoekstra und Romme (1991), Fisher (1997) oder Olhager (2003, 2010).

²⁵Vgl. beispielsweise D'Alessandro und Baveja (2000), van Donk (2001) und Meyr (2004). D'Alessandro und Baveja (2000) untersuchen verschiedene Entkopplungspunkte in der chemischen Industrie. van Donk (2001) analysieren den Entkopplungspunkt in einer lebensmittelverarbeitenden Supply Chain. Meyr (2004) beschreibt die besonderen Charakteristika des Entkopplungspunkts in der deutschen Automobilindustrie.

Einflussfaktoren für eine Position weiter upstream in der Wertschöpfungskette

Hoekstra und Romme (1991, S. 69 ff.) nennen zwei wesentliche Faktoren, die eine Positionierung des Entkopplungspunkts weiter upstream in der Wertschöpfungskette begünstigen und weiter downstream begrenzen:²⁶

1. Eigenschaften des vorliegenden Produkts und Markts
2. Lagerhaltungskosten

Bei den vorliegenden Produkt- und Markteigenschaften ist die Volatilität der Nachfrage ein wichtiger Aspekt, den neben Hoekstra und Romme (1991, S. 69 ff.) auch Olhager (2003, 2010) hervorhebt.

Wie bereits erwähnt, wird die Fertigung bis zum Entkopplungspunkt auf Grundlage von Prognosen geplant und gesteuert. Die Produkte werden als Zwischenprodukte in ihrem aktuellen Zustand am Entkopplungspunkt eingelagert. Diese Zwischenprodukte können zu verschiedenen Endprodukten verarbeitet werden. Dabei sinkt die Zahl der Endprodukte, für die ein Zwischenprodukt verwendet werden kann, je weiter downstream in der Wertschöpfungskette es sich befindet. Grund dafür ist die zunehmende Spezifität dieser Zwischenprodukte, die aus der weiteren Verarbeitung und der damit verbundenen Differenzierung resultiert, wie von Alderson (1950) im Rahmen des Postponements beschrieben. Dies bedeutet, dass die Zwischenprodukte am Entkopplungspunkt eine höhere Spezifität haben, wenn dieser weiter downstream in der Wertschöpfungskette positioniert ist.

Für die Planung und Steuerung der Schritte vor dem Entkopplungspunkt muss der Bedarf an Zwischenprodukten am Entkopplungspunkt prognostiziert werden. Dieser Bedarf resultiert aus der Nachfrage nach allen Endprodukten, für die dieses Zwischenprodukt benötigt wird. Wenn der Bedarf an diesen Zwischenprodukten stärker schwankt, sind größere Abweichungen der tatsächlichen von der vorhergesagten Menge zu erwarten. In diesem Fall sind größere Sicherheitsbestände der Zwischenprodukte in der Lagerhaltung am Entkopplungspunkt aufzubewahren, um diese Schwankungen ausgleichen zu können. Diese Sicherheitsbestände verursachen allerdings Kosten, weshalb eine geringe Nachfragevolatilität bei den Zwischenprodukten wünschenswert ist.

Hoekstra und Romme (1991, S. 69 ff.) stellen dabei fest, dass die Lagerhaltungskosten für die Zwischenprodukte am Entkopplungspunkt meistens steigen, wenn dieser weiter downstream positioniert ist. Sie nennen dafür mehrere Gründe. Unter anderem ist dies dadurch begründet, dass der Wert der Produkte durch die Verarbeitung sukzessive zunimmt. Die Lagerhaltung höherwertigerer Produkte downstream in der Wertschöpfungskette ist deshalb teurer. Außerdem wächst mit der zunehmenden Spezifität meist die Anzahl der unterschiedlichen Varianten zu lagernder Zwischenprodukte. Statt einer größeren Menge weniger Zwischenprodukte müssen weiter downstream meist kleinere Mengen einer größeren Zahl von Zwischenprodukten gelagert werden, was aufwendiger ist. Gleichzeitig

²⁶Es sind diese beiden Faktoren, die auch von den meisten anderen Autoren in ihren Veröffentlichungen zur Entkopplungspunktpositionierung in der einen oder anderen Form aufgegriffen werden. Vgl. beispielsweise van Donk (2001) oder Olhager (2003, 2010). Die folgenden Ausführungen zu den Einflussfaktoren basieren auf den genannten Arbeiten.

sinkt mit der zunehmenden Spezifität eines Zwischenprodukts die Zahl der möglichen Kunden und damit der Bedarf. Wie Olhager (2003) erkennt, ist die relative Nachfragevolatilität bei diesen kleineren Bedarfsmengen größer. Es besteht das Risiko, dass manche Zwischenprodukte länger eingelagert werden müssen oder sogar veralten, wenn es eine Weile nur eine geringe bis gar keine Nachfrage dafür gibt.

Bei der Positionierung des Entkopplungspunkts ist entsprechend die Entwicklung der Produktspezifität, Nachfragevolatilität und Lagerhaltungskosten zu untersuchen und bewerten. Die mit unterschiedlichen Entkopplungspunktpositionen verbundenen Kosten und Risiken sind vor dem Hintergrund der betrachteten Wertschöpfungskette mit ihren speziellen Eigenschaften zu bestimmen und in die Planung einzubeziehen. In einer Supply Chain, die dem Kunden zahlreiche maßgeschneiderte Produktvarianten anbietet, ist der Einfluss dieser Faktoren größer, als wenn sie nur einige wenige standardisierte Endprodukte im Markt platziert.

Hervorzuheben ist in diesem Zusammenhang der bereits beschriebene Point of Differentiation. Wie Meyr (2003) erläutert hat, sollte der Entkopplungspunkt upstream eines solchen Point of Differentiation positioniert werden. Liegt der Entkopplungspunkt nämlich weiter downstream, steigen Produktspezifität, Nachfragevolatilität und Lagerhaltungskosten stark an. Olhager (2010) kommt zu einem ähnlichen Ergebnis. Er beschreibt, dass in den Aktivitäten vor dem Entkopplungspunkt nur vergleichsweise standardisierte und somit unspezifische Versionen eines Produkts bearbeitet werden sollten, die noch geringe Bedarfsschwankungen aufweisen und entsprechend gut zu prognostizieren sind.

Das verallgemeinerte Auftragsprofil, das eine ex-post Erfassung²⁷ und Bewertung des Bestellungseingangs und der Nachfrage ermöglicht, erlaubt es in diesem Zusammenhang, die Nachfragevolatilität in der Supply Chain zu bewerten. Durch die explizite Betrachtung unterschiedlicher Aggregationsebenen von Endprodukten im verallgemeinerten Auftragsprofil können die Bedarfsschwankungen bei den Zwischenprodukten an unterschiedlichen Entkopplungspunktpositionen analysiert werden. Es wird so möglich, die Nachfragevolatilität für eine Repositionierung des Entkopplungspunkts zu quantifizieren und in der Planung zu berücksichtigen.

Einflussfaktoren für eine Position weiter downstream in der Wertschöpfungskette

Die Erwartungen des Markts an die Lieferzeit und -zuverlässigkeit sind wesentliche Faktoren, die die Entkopplungspunktpositionierung weiter downstream in der Wertschöpfungskette treiben und eine Upstream-Verschiebung beschränken. Die Lieferzeiterwartungen des Markts werden durch die Wunschlieferzeitpunkte beschrieben, die die Kunden bei ihren Bestellungen angeben. Die Vorlaufzeit zwischen Bestellungseingang und Wunschlieferzeitpunkt entspricht den Markterwartungen zur Lieferzeit für diesen Auftrag. Dabei sollte eine Supply Chain langfristig diese Erwartungen erfüllen, um am Markt erfolgreich zu bestehen, wie Hoekstra und Romme (1991, S. 69 ff.) feststellen.

Die Lieferzeit einer Supply Chain ist durch die Aktivitäten, die nach dem Entkopplungspunkt auszuführen sind, und deren Durchlaufzeiten, die der Zeitdauer für deren

²⁷Eine ex-post Erfassung bezieht sich in dieser Arbeit immer ausschließlich auf Vergangenheitswerte. Wenn die Gegenwart der Zeitpunkt t_1 ist, sind dies Werte, die der Supply Chain zu einem Zeitpunkt t_2 bekannt waren, wobei $t_2 \leq t_1$ gilt.

Durchführung entsprechen, bestimmt. Wie bereits erläutert, wird in Kapitel 6 erstmals ein Verfahren beschrieben, das es erlaubt, den tatsächlichen Entkopplungspunkt ex-post zu messen. Indem die verschiedenen Liefer- und Vorlaufzeiten ex-post abgeglichen werden, kann der Entkopplungspunkt ermittelt werden. Die Ergebnisse dieser Untersuchung können als Grundlage genutzt werden, um mögliche Schwachstellen in der Planung von Wertschöpfungsschritten aufzudecken und Optimierungspotentiale herauszuarbeiten. Die Analyse kann als eine wichtige Grundlage für langfristige strategische Überlegungen zur Entkopplungspunktposition eingesetzt werden.

Neben den Lieferzeiten ist auch die Lieferzuverlässigkeit für die Entkopplungspunktposition wichtig. Ein wesentlicher Aspekt für die Lieferzuverlässigkeit ist die Steuer- und Planbarkeit des Herstellungsprozesses. Gibt es Aktivitäten in der Herstellung, deren Durchlaufzeiten stark schwanken und nur schwer planbar sind, kann dies zu verspäteten Auslieferungen führen. Hoekstra und Romme (1991, S. 122 ff.) nennen exemplarisch einige Aktivitäten, die solche Planungsprobleme aufweisen können. Dies sind unter anderem komplexe und riskante Produktionsschritte sowie Aktivitäten, bei denen Produktionskapazitäten verwendet werden, die häufig einen Engpass aufweisen. Hoekstra und Romme (1991, S. 122 ff.) schreiben, dass der Entkopplungspunkt downstream von solchen Aktivitäten liegen sollte, um eine hohe Lieferzuverlässigkeit zu gewährleisten. Die Thematik der Lieferzuverlässigkeit sowie Steuerbarkeit von Produktionsschritten wird hier der Vollständigkeit halber genannt, wird in dieser Arbeit jedoch nicht weiter untersucht.

2.5. Bedeutung verschiedener Prognosemethoden für das Demand Planning

Wie bereits in Abschnitt 2.2 erläutert, ist die Prognose der zukünftigen Nachfrage eine Aufgabe, die zum Planungsmodul Demand Planning gehört. Entsprechend betrifft die Analyse und Identifikation von Situationen, in denen der Einsatz ADI-basierter Prognosemethoden geeignet ist, vor allem dieses Planungsmodul. Das Demand Planning wird detailliert von Kilger und Wagner (2008) sowie Meyr (2012) erläutert. Die folgenden Ausführungen zu diesem Planungsmodul basieren auf diesen beiden Arbeiten.

Kilger und Wagner (2008) identifizieren drei wichtige Themenbereiche, die bei der Vorhersage der zukünftigen Nachfrage zu beachten sind. Sie beziehen sich auf die Struktur, den Prozess und die Überprüfung der Nachfrageprognose. Die Themen lassen sich durch folgende Fragen gut beschreiben:

1. Struktur der Prognose: Welche Nachfrage soll prognostiziert werden? Was ist die relevante Aggregationsebene und welche Informationen werden für die Prognosen benötigt?
2. Prozess der Prognose: Wie sieht der Vorhersageprozess aus? Wer ist daran in welchen Prozessschritten beteiligt?
3. Überprüfung der Prognose: Wie können Prognosen kontrolliert und überprüft werden? Was sind relevante Qualitätsmaße und welche Maßnahmen sind bei unzureichender Prognosequalität gegebenenfalls zu ergreifen?

Die Relevanz unterschiedlicher Aggregationsebenen für das Supply Chain Management wurde zu Beginn dieses Kapitels bereits dargestellt. Wie Kilger und Wagner (2008) feststellen, leitet sich die für die Prognose relevante Aggregationsebene aus der Planungsaufgabe ab, die die Vorhersage benötigt. Die betrachtete Aggregationsebene ist dem eigentlichen Prognoseprozess also vorgegeben.²⁸

Wie bereits in Abschnitt 2.1 dargestellt, existieren in einer Supply Chain mehrere Planungsebenen. Sie unterscheiden sich in der Granularität der betrachteten Aggregationsebene sowie dem Zeithorizont der getroffenen Entscheidungen. Dabei steigt der Detailgrad bzw. die Granularität der Planung mit sinkendem Zeithorizont. Die Planung eines neuen internationalen Produktionsstandorts bedarf beispielsweise eines längeren Planungshorizonts und der Betrachtung einer höheren Aggregationsebene als die regionale Transportplanung der kommenden Woche. Das Konzept der hierarchischen Produktionsplanung sucht hier einen integrativen Planungsansatz für die Supply Chain bereitzustellen.²⁹ Für die diversen Planungsaufgaben werden entsprechende Nachfrageprognosen auf den unterschiedlichsten Aggregationsebenen benötigt. Die relevanten Aggregationsebenen sind dabei meist nicht überschneidungsfrei. Die in unterschiedlichen Prognosen betrachteten Kunden, Produkte und Bestellungseingangsstellen werden sich teilweise überdecken. So kann sich eine nationale Nachfrageprognose mit der einer Bestellungseingangsstelle im gleichen Land überschneiden. Beide sind wiederum in einer globalen Vorhersage vollständig enthalten.³⁰ Um die Konsistenz der Vorhersagen zu gewährleisten, wurde beispielsweise das *Hierarchical Forecasting* entwickelt.³¹




Abbildung 2.14.: Prozess zur Nachfrageprognose aus Kilger und Wagner (2008)

Als mögliches Verfahren zur Prognose zukünftiger Nachfrage wurde der in Abbildung 2.14 dargestellte Prozess von Kilger und Wagner (2008) vorgeschlagen. Er unterteilt den Prozess zur Erstellung einer Bedarfsvorhersage in sechs Schritte. Im ersten Schritt wird primär die relevante Aggregationsebene bestimmt und es werden gegebenenfalls historische Daten für den weiteren Prozess aufbereitet. Es folgt die Berechnung von Prognosen mit statistischen Methoden, wie es beispielsweise die ADI-basierten sind. Ein Problem statistischer Methoden ist, dass sie nicht alle Informationen verarbeiten und in die Berechnung einbeziehen können. Der Start eines neuen Produktmodells oder eine

²⁸Im Gegensatz dazu untersuchen Zotteri u.a. (2005) den Einfluss unterschiedlicher Aggregationsebenen auf die Prognosegenauigkeit. Sie ermitteln Aggregationsebenen, die aus ihrer Sicht für die Prognose besonders geeignet sind.

²⁹Zu hierarchischen Produktionsplanung vgl. u.a. Hax und Meal (1975), Hax und Golovin (1978), Bitran und Hax (1977), Bitran u.a. (1981, 1982), Stadtler (1986) sowie Schneeweiss (2003, S. 159–204).

³⁰Zu den Ausführungen zu unterschiedlichen Aggregationsebenen bei Nachfrageprognosen vgl. Kilger und Wagner (2008).

³¹Zum Hierarchical Forecasting vgl. u.a. Flidner und Mabert (1992) sowie Flidner (1999).

geplante Marketing-Kampagne fließen so in die Prognose nicht mit ein. Diese Informationen werden, wie in Abbildung 2.14 dargestellt, im Rahmen des *Judgmental Forecasting* eingebunden. Planer aus unterschiedlichen Abteilungen sind an der Prognose in diesem Prozessschritt beteiligt. Dies beinhaltet unter anderem häufig Mitarbeiter aus dem Vertrieb und Marketing. Armstrong und Collopy (1998) präsentieren mehrere Optionen zur Integration der statistischen Prognosen in das Judgmental Forecasting. Der Nutzen einer Kombination von statistischen Prognosen und Judgmental Forecasting wird ebenfalls von Lawrence u.a. (1986) untersucht. Die Eingaben der am Judgmental Forecasting beteiligten Personen können sich unterscheiden. Durch die Diskussion und Gewichtung dieser verschiedenen Eingaben muss ein Prognosekonsens gefunden werden. Dieser Prognosekonsens wird allerdings noch nicht offiziell bekanntgegeben. Die davon abhängige Nachfrage muss zunächst berechnet und überprüft werden. Der Prognosekonsens bezieht sich auf eine Menge von Endprodukten. Der aus dieser Menge resultierende Bedarf an Komponenten, die Teil dieser finalen Produkte sind, wird als abhängige Nachfrage bezeichnet. Prognostiziert beispielsweise ein Automobilhersteller einen Absatz von 1.000 Fahrzeugen, ergibt sich daraus unter anderem eine abhängige Nachfrage nach 4.000 Reifen, 2.000 Rücklichtern und 1.000 Lenkrädern. Bevor der Prognosekonsens veröffentlicht wird, muss überprüft werden, ob die abhängige Nachfrage bekannten Markttrends und -vorhersagen widerspricht. In dem Fall ist der Prognosekonsens gegebenenfalls zu überarbeiten.

Einen anderen Prozess zur Erstellung von Nachfrageprognosen hat Tan (2008) entwickelt. Im Gegensatz zu dem Prozess von Kilger und Wagner (2008) integriert diese Vorgehensweise unvollständige ADI³² in die Prognoseerstellung. Dabei wird der Prognosekonsens unter Einsatz verschiedener mathematischer Formeln mit der unvollständigen ADI kombiniert, um eine finale Prognose zu ermitteln.

Helms u.a. (2000) sowie Aviv (2001) haben die Vorteile eines sogenannten *Collaborative Forecastings* für den Erfolg der Supply Chain analysiert. Idee des Collaborative Forecastings ist es, dass die Organisationen einer Supply Chain nicht nur Informationen in Form von ADI austauschen, sondern auch gemeinsam Prognosen der künftigen Nachfrage erstellen und abstimmen. Helms u.a. (2000) fokussieren ihre Ausführungen auf die Beschreibung des eigentlichen Prozesses des Collaborative Forecastings und die damit verbundenen Herausforderungen, Probleme und Vorteile. Aviv (2001) modelliert jeweils eine Supply Chain mit und ohne Collaborative Forecasting, um die Vorteile grob zu quantifizieren.

Die in dieser Arbeit durchgeführte Analyse ADI-basierter Prognosemethoden bezieht sich auf den Einsatz statistischer Verfahren in den verschiedenen Prognoseprozessen. Wie die Ergebnisse von Haberleitner u.a. (2010) zeigen, können ADI-basierte Prognosemethoden in einigen Situationen sehr gute Nachfrageprognosen erzeugen. Sie tun dies allerdings nicht immer und es existieren Situationen, in denen andere Methoden bessere Resultate liefern. Ziel ist es, die Eignung ADI-basierter Prognosemethoden in einer Planungssi-

³²Bei unvollständiger ADI kann sich die Bestellmenge im Zeitverlauf noch verändern. So ist auch eine vollständige Stornierung noch möglich. Unvollständige ADI wird auch häufig als imperfect ADI bezeichnet.

tuation zu bewerten. Dies ist vor allem hilfreich, da es bisher keine fertigen und leicht integrierbaren Softwaremodule für die ADI-basierten Prognosemethoden gibt. Die Supply Chain muss die Methoden deshalb vor einem Einsatz eigenständig implementieren, wie Haberleitner u.a. (2010) exemplarisch beschreiben. Weil eine solche Implementierung in einem APS sehr aufwendig ist, will eine Supply Chain die Implementierung nur durchführen, wenn dadurch die zu erwartende Prognosequalität steigt. Die Analyseergebnisse in dieser Arbeit erlauben es erstmals, eine solche Bewertung der ADI-basierten Prognosemethoden vor ihrer Implementierung in einem APS durchzuführen. Um diese Beurteilung der Methoden zu ermöglichen, werden nur die ADI ex-post analysiert. Es wird dabei nicht der Einsatz der ADI-basierten Prognosemethoden ex-post simuliert, da eine Implementierung in einem APS ausgeschlossen werden soll.

Es besteht natürlich die Möglichkeit, die ADI-basierten Prognosemethoden für die ex-post Durchführung der Simulation beispielsweise in einem Tabellenkalkulationsprogramm zu implementieren. Der Aufwand einer solchen Implementierung wäre deutlich geringer als in einem APS. Wie bereits in Kapitel 1 beschrieben, ist das für eine solche Implementierung notwendige Wissen zu den ADI-basierten Prognosemethoden in vielen Supply Chains nicht vorhanden, weshalb die Kennzahlen, die in Kapitel 5 vorgestellt werden, eine deutliche einfachere Einschätzung der Methoden ermöglichen.

Zur Kontrolle und Überprüfung der Prognosegüte wurden zahlreiche Metriken identifiziert.³³ Nach den Umfrageergebnissen von Carbone und Armstrong (1982) sind es dabei für eine Vielzahl von Anwendern statistische Kriterien, die bei der Bewertung von Prognosemethoden besonders relevant sind. Demski und Feltham (1972) kamen ebenfalls zu dem Ergebnis, dass zur Bewertung von Prognosefehlern meist statistische Standardmaße benutzt werden. Entsprechend werden in der folgenden Analyse statistische Kriterien zur Bewertung der Prognosegenauigkeit verwendet. Einige der häufig verwendeten Standardmaße werden in Kapitel 7 erläutert.

2.6. Zusammenfassung

In diesem Kapitel wurde ein Überblick über die Planungsaufgaben im Supply Chain Management gegeben. Es wurde dabei die Relevanz unterschiedlicher Planungsebenen vorgestellt und die Supply Chain Planning-Matrix als strukturierendes Element erläutert. Die neun Planungsmodule der Supply Chain Planning-Matrix wurden skizziert und die Interdependenzen zwischen den Modulen beschrieben. Diese Matrix erlaubt es, die wesentlichen Planungsaufgaben des Supply Chain Managements systematisch und übersichtlich zu beschreiben. Sie wurde in diesem Kapitel als Grundlage genutzt, um die Bedeutung der untersuchten Fragestellungen für das Supply Chain Management hervorzuheben.

In Kapitel 6 dieser Arbeit wird erstmals ein Verfahren vorgestellt, das es ex-post erlaubt, den Entkopplungspunkt in einer Wertschöpfungskette zu bestimmen. Das Entkopplungspunktkonzept wurde deshalb in diesem Kapitel detailliert erläutert und das damit verbundene Prinzip des Postponements vorgestellt. Die Problematik, die aus einer man-

³³Vgl. beispielsweise Armstrong (2001).

gelnden Berücksichtigung des sukzessiven Bestellungseingangs resultiert, wurde ebenfalls beschrieben und das von Meyr (2003) eingeführte Auftragsprofil zur Darstellung dieses Bestellverhaltens umfassend erklärt. Die Identifikation der Entkopplungspunktposition ist gleichzeitig für verschiedene operative und strategische Planungsaufgaben in einer Supply Chain wichtig. Mit dem in Kapitel 6 vorgestellten Verfahren können die Implikationen des Entkopplungspunkts für die diversen Planungsaufgaben erstmals quantitativ bewertet und berücksichtigt werden.

Die Untersuchung der ADI-basierten Prognosemethoden ist vor allem für das Demand Planning relevant, wie ebenfalls in diesem Kapitel erklärt wurde. In den Kapiteln 7 und 8 wird gezeigt, wie eine Supply Chain feststellen kann, ob sich diese Methoden für die statistische Berechnung der benötigten Prognosen eignen. Weil diese Methoden bisher mit hohem Aufwand von einer Supply Chain in einem APS implementiert werden müssen, ist es für sie von großem Mehrwert, wenn sie die Qualität der von diesen Methoden zu erwartenden Vorhersagen vorab abschätzen kann. Ist von den ADI-basierten Methoden keine Verbesserung der Prognosequalität zu erwarten, kann die Supply Chain den Implementierungsaufwand einsparen. Die in den Kapiteln 7 und 8 vorgestellten Kennzahlen ermöglichen es, diese Verbesserung der Prognosequalität besonders einfach abzuschätzen und sind auch für Anwender ohne Fachkenntnisse anwendbar.

In den Kapiteln 3 bis 5 wird nun zunächst dargestellt, wie die ADI ex-post strukturiert erfasst und bewertet werden kann. Das beschriebene Vorgehen erlaubt es, das Bestellverhalten rückwirkend zu charakterisieren. Die Erkenntnisse aus dieser Analyse sind, wie in den danach folgenden Kapiteln gezeigt werden wird, für die Bestimmung des Entkopplungspunkts oder die Untersuchung von ADI-basierten Prognosemethoden wichtig.

3. Das verallgemeinerte Auftragsprofil

In diesem Kapitel wird eine strukturierte und ganzheitliche ex-post Erfassung der ADI vorgestellt. Sie ist die Grundlage für deren anschließende Nutzung bei den unterschiedlichsten Planungsaufgaben. Die Ausführungen basieren auf den Ideen von Meyr (2003) zum Auftragsprofil, das im letzten Kapitel vorgestellt wurde. Die Ideen werden allerdings gleichzeitig systematisch ausgebaut und verallgemeinert. Es erfolgt zunächst in Abschnitt 3.1 eine umfassende Vorstellung aller relevanten Variablen für das Auftragsprofil, das hier aufgrund seiner Erweiterungen gegenüber Meyr (2003) als verallgemeinertes Auftragsprofil bezeichnet wird. Eine wesentliche Erweiterung gegenüber Meyr (2003) ist die Berücksichtigung unterschiedlicher Aggregationsebenen, die für eine Supply Chain bei der Bearbeitung der verschiedenen Planungsaufgaben relevant sein können. In Abschnitt 3.2 werden Durchschnitts- und Streuungswerte zu diesen Variablen vorgestellt. Es sind diese Werte zur Beschreibung des durchschnittlichen Bestellverhaltens, die ein verallgemeinertes Auftragsprofil definieren.

3.1. Definition der Variablen

3.1.1. Die Bestellung

Grundlage jedes verallgemeinerten Auftragsprofils ist eine einzelne Bestellung, in der ein Kunde eine gewisse Menge eines bestimmten Produkts anfordert. In dieser Arbeit wird davon ausgegangen, dass in einer Bestellung folgende Aspekte klar definiert sind:¹

- Ein für die Supply Chain **eindeutig identifizierbarer Kunde**, bspw. durch Angabe einer Kundennummer.
- Ein für die Supply Chain **eindeutig identifizierbares Produkt**, bspw. eine klar definierte SKU².
- Eine **eindeutig definierte Bestellungseingangsstelle**, bspw. die für den Kunden zuständige Landesgesellschaft.

¹In einigen Supply Chains kann es vorkommen, dass bei einer Bestellung nicht alle diese Aspekte eindeutig bestimmbar sind. Es ist in diesen Situationen eine alternative Definition der Variablen vorzunehmen. Insbesondere der Wunschlieferzeitpunkt wird nicht von allen Supply Chains erfasst. Wie bereits in Kapitel 2 erläutert, unterscheiden Gollwitzer und Karl (1998, S. 68–71) drei Lieferzeitpunkte. Neben dem Wunschlieferzeitpunkt sind dies der dem Kunden versprochene sowie der tatsächliche Lieferzeitpunkt. Alternativ können auch diese beiden anderen Lieferzeitpunkte zur Definition der Variablen verwendet werden. Dies muss dann allerdings klar hervorgehoben und die Implikationen für die Planungsaufgabe, in der die ADI eingesetzt werden, untersucht werden.

²*Stock Keeping Unit* (SKU) ist üblicherweise ein solches eindeutig identifizierbares Produkt.

- Der genaue **Zeitpunkt des Bestellungseingangs** sowie ein **Wunschlieferzeitpunkt**. Je nach Genauigkeit der Erfassung kann sich ein solcher Zeitpunkt auf eine bestimmte Woche, einen Tag oder sogar eine Uhrzeit beziehen.
- Eine die **Bestellmenge definierende Maßeinheit**. Dies kann sowohl ein monetäres (z.B. € oder US\$) als auch ein nicht-monetäres (Stück, Liter, kg etc.) Maß sein.

Zur Verdeutlichung sei folgendes kurzes Beispiel angeführt: Der Elektrohändler *Jupiter* bestellt am 23. Oktober des laufenden Jahres 10.000 Radiowecker vom Typ *Weckmich* über die deutsche Landesgesellschaft der Supply Chain und wünscht Lieferung am 30. November desselben Jahres. Der Kunde ist in diesem Beispiel der Elektrohändler *Jupiter*, für den der Supply Chain die notwendigen Informationen zur Bestellungsabwicklung vorliegen - z. B. Liefer- und Rechnungsadresse. Das Produkt ist der Radiowecker *Weckmich* und Bestellungseingangsstelle ist die deutsche Landesgesellschaft der Supply Chain. Zeitpunkt des Bestellungseingangs ist der 23. Oktober und Wunschlieferzeitpunkt der 30. November des laufenden Jahres. Die Bestellmenge wird in Stück gemessen. In diesem Beispiel sind es 10.000 Stück.

Für das verallgemeinerte Auftragsprofil werden diese Werte abstrahiert. Es wird dafür der eindeutig identifizierte aber beliebige Kunde i , das Produkt j sowie die Bestellungseingangsstelle k betrachtet. Es wird weiter angenommen, dass die Bestellung zum beliebigen Zeitpunkt t mit Wunschlieferzeitpunkt s eingegangen ist, wobei $t \leq s$ gilt. Als Basis des verallgemeinerten Auftragsprofils repräsentiert die folgende Variable nun eine solche Bestellung:

$d_{ijk(s-t)s}$ Bestellmenge eines Kunden i für Produkt j über Bestellungseingangsstelle k , eingegangen zum Zeitpunkt t mit Wunschlieferzeitpunkt s

Die Maßeinheit wird an dieser Stelle nicht explizit aufgeführt. Es wird davon ausgegangen, dass diese vorab klar definiert und anschließend durchgängig einheitlich verwendet wird. Dass unterschiedliche Maßeinheiten einen signifikanten Effekt auf das resultierende Auftragsprofil haben können, wird später noch dargelegt. Folgende zwei Besonderheiten sind bei dieser Definition zu beachten:

1. Bestellt derselbe Kunde i mehrfach das gleiche Produkt j zum Zeitpunkt t mit Wunschlieferzeitpunkt s über die Bestellungseingangsstelle k , so werden diese Bestellungen hier zu einer zusammengefasst, indem die Bestellmengen addiert werden.
2. Sind in einer Bestellung mehrere Produkte enthalten, so werden die unterschiedlichen Auftragspositionen als eigenständige Bestellungen betrachtet.

Bestellt also in obigem Beispiel der Elektrohändler *Jupiter* neben dem Radiowecker *Weckmich* noch die Kaffeemaschine *Filterfein*, dann werden die Radiowecker und Kaffeemaschinen als zwei getrennte Bestellungen aufgefasst. Geht ferner am 23. Oktober eine weitere Bestellung für Radiowecker des Typs *Weckmich* vom Elektrohändler *Jupiter* für den 30. November ein, so werden die beiden Bestellmengen hier summiert und fortan

als eine Bestellung betrachtet. Die Differenz zwischen dem Bestellungseingang und dem Wunschlieferzeitpunkt wird als Vorlaufzeit bezeichnet. Im Fall eines Bestellungseingangs zum Zeitpunkt t mit Wunschlieferzeitpunkt s ist die Vorlaufzeit e als $e = s - t$ definiert. Dadurch vereinfacht sich auch die Syntax obiger Variable zu $d_{ijk\text{es}}$. Für das Beispiel des Elektrohändlers beträgt die Vorlaufzeit 38 Tage, wenn Feiertage und Wochenenden als normale Werktage betrachtet und mitgezählt werden. Abschließend ist zu betonen, dass es durch Stornierungen auch möglich ist, dass $d_{ijk\text{es}}$ einen negativen Wert annimmt.

3.1.2. Kumulation von Bestellinformationen

Wie beschrieben ist die einzelne Bestellung die Grundlage eines jeden Auftragsprofils. Für die Analyse von Bestellinformationen sind allerdings zwei zeitlich kumulierte Bestellmengen von großem Interesse:

1. Die Bestellmenge, die ein Kunde bis zu einem bestimmten Zeitpunkt für einen späteren Wunschlieferzeitpunkt bestellt hat.
2. Die zu einem bestimmten Zeitpunkt noch ausstehende Bestellmenge für einen späteren Wunschlieferzeitpunkt.

Für obiges Elektrohändlerbeispiel wäre dies die Menge an Radioweckern, die bis zum 23. Oktober für den 30. November bestellt wurde, bzw. die Bestellmenge, die in der verbleibenden Zeit noch eingehen wird. Für die abstrakte Definition dieser Werte werden die beiden folgenden Variablen verwendet:

$D_{ijk\text{es}}$	Kumulierte Bestellmenge eines Kunden i für Produkt j über Bestellungseingangsstelle k , eingegangen <u>bis</u> zu e Perioden vor dem Wunschlieferzeitpunkt s .
$U_{ijk\text{es}}$	Noch ausstehende Bestellmenge eines Kunden i für das Produkt j über Bestellungseingangsstelle k genau e Perioden vor dem Wunschlieferzeitpunkt s .

Die erste Variable entspricht der Addition aller Bestellungen mit Wunschlieferzeitpunkt s , die für die ausgewählte Kombination aus Kunde, Produkt und Bestellungseingangsstelle bis zum Zeitpunkt t eingegangen sind. Dies sind alle Bestellungen mit einer Vorlaufzeit von mindestens e . Wenn M die maximale Vorlaufzeit ist, mit der Bestellungen eingehen, dann gilt $D_{ijk\text{es}} = \sum_{h=e}^M d_{ijkhs}$. Die zweite Variable $U_{ijk\text{es}}$ hingegen ist die Summation aller Bestellungen für s , die zum Zeitpunkt t noch nicht vorliegen, also eine kürzere Vorlaufzeit als e haben. Es gilt $U_{ijk\text{es}} = \sum_{h=0}^{e-1} d_{ijkhs}$.

Eine besondere Stellung nimmt die Variable D_{ijk0s} ein. Sie entspricht der Summe aller für den Zeitpunkt s eingegangenen Bestellungen und repräsentiert damit die tatsächliche Gesamtnachfrage. Die Addition der Variablen $D_{ijk\text{es}}$ und $U_{ijk\text{es}}$ ergibt stets diese Gesamtnachfrage zum Wunschlieferzeitpunkt.³

³Dies gilt auch bei Stornierungen. In diesem Fall ist dann gegebenenfalls $U_{ijk\text{es}} < 0$. Stornierungen, die nach dem Wunschlieferzeitpunkt eingehen und bei denen $U_{ijk\text{es}} < 0$ für $e < 0$ gilt, werden in dieser Arbeit nicht betrachtet.




Abbildung 3.1.: Zusammenhang einfache und kumulierte Bestellmengen

Die Zusammenhänge zwischen den Variablen soll Abbildung 3.1 verdeutlichen. Auf der linken Seite sind die einfachen Bestellmengen eines beliebigen Kunden i für beliebiges Produkt j , eingegangen über die Bestellungseingangsstelle k mit Wunschlieferszeit $s = 56$, aufgetragen. So beträgt beispielsweise die Bestellmenge mit einer Vorlaufzeit von $e = 4$ zum Zeitpunkt 52 $d_{ijk52} = 40$. Insgesamt geht für den Wunschlieferszeitpunkt $s = 56$ eine Bestellmenge von 120 mit einer Vorlaufzeit von bis zu $e = 6$ ein. Die Kumulation dieser Werte findet sich auf der rechten Seite grau unterlegt. Zum Zeitpunkt $t = 51$ ist beispielsweise bereits eine Bestellmenge von 30 eingegangen: $d_{ijk56} + d_{ijk55} = 10 + 20 = 30$. Deshalb gilt $D_{ijk55} = 30$. Gleichzeitig ist zu diesem Zeitpunkt noch eine Bestellmenge von $U_{ijk55} = 90$ ausstehend: $d_{ijk54} + d_{ijk53} + d_{ijk52} + d_{ijk51} + d_{ijk50} = 40 + 35 + 10 + 5 + 0 = 90$. Die Addition der beiden Werte D_{ijk55} und U_{ijk55} ergibt die Gesamtnachfrage von 120.

3.1.3. Bestellmengen und Aggregation

Neben der beschriebenen Kumulation von Bestellmengen über die Vorlaufzeiten hinweg ist die explizite Betrachtung unterschiedlicher Aggregationsebenen ein wichtiger Bestandteil des verallgemeinerten Auftragsprofils. In diesem Abschnitt wird die Aggregation planungsrelevanter Objekte untersucht. Eine Aggregation in der zeitlichen Dimension wird im nächsten Abschnitt erläutert.

Bislang wurde davon ausgegangen, dass einzelne eindeutig identifizierbare Kunden, Produkte und Bestellungseingangsstellen im verallgemeinerten Auftragsprofil erfasst werden. Diese Einschränkung wird nun aufgehoben. Es werden nun auch Aggregationsebenen dieser drei planungsrelevanten Objekte betrachtet. Wenn beispielsweise die Supply Chain ex-post nicht nur die Bestelleingänge des Elektronikhändlers *Jupiter*, sondern die des gesamten nationalen Markts für den Radiowecker *Weckmich* analysieren will, so ist nicht

mehr ein einzelner, sondern eine Menge von Kunden relevant. Wie diese aggregierte Menge von Kunden aussieht, ist dabei von der jeweiligen Analyse bzw. Planungsaufgabe der Supply Chain abhängig. So kann sie statt des nationalen Markts bei einer Analyse des Großkundengeschäfts auch alle Kunden mit einem bestimmten Mindestumsatz enthalten. Die Relevanz unterschiedlicher Aggregationsebenen für das Supply Chain Management und das Demand Planning wurde bereits im letzten Kapitel dargestellt.

Verallgemeinernd wird hier eine beliebige Gruppe von Kunden I untersucht. Die betrachtete Aggregationsebene enthält nun alle Kunden aus I , die das Produkt j über die Bestellungseingangsstelle k bestellen. Sowohl die einfachen als auch die kumulierten Bestellmengen sind nun als Summe der jeweiligen Bestellmengen aller in I enthaltenen Kunden definiert. Es gilt also $d_{Ijkes} := \sum_{h \in I} d_{hjkes}$, $D_{Ijkes} := \sum_{h \in I} D_{hjkes}$ und $U_{Ijkes} := \sum_{h \in I} U_{hjkes}$.

Die Aggregation ist allerdings nicht auf die Kunden begrenzt. Es ist genauso möglich, Produkte oder Bestellungseingangsstellen zu aggregieren. Möchte die Supply Chain das Geschäft für sämtliche Radiowecker in ihrem Produktportfolio analysieren oder das Geschäft für alle Bestellungseingangsstellen im europäischen Raum betrachten, so muss auch hier eine höhere Aggregationsebene zugrunde gelegt werden.

Eine beliebige Produktgruppe wird fortan mit J und eine Gruppe von Bestellungseingangsstellen mit K abgekürzt. Die Aggregation von Kunden, Produkten und Bestellungseingangsstellen kann natürlich auch kombiniert werden, so dass sich bei der Betrachtung der Mengen I , J und K folgende aggregierte Bestellmengen ergeben:

- $d_{IJKes} := \sum_{h \in I} \sum_{g \in J} \sum_{f \in K} d_{hgfes}$,
- $D_{IJKes} := \sum_{h \in I} \sum_{g \in J} \sum_{f \in K} D_{hgfes}$ und
- $U_{IJKes} := \sum_{h \in I} \sum_{g \in J} \sum_{f \in K} U_{hgfes}$.

Für das bisher verwendete Beispiel eines Herstellers von Elektroartikeln kann so eine mögliche Aggregationsebene sämtliche Handelsketten aus den USA (Kundengruppe I), die einen LCD-Fernseher (Produktgruppe J) über eine der weltweiten Vertriebsgesellschaften (Gruppe der Bestellungseingangsstellen K) geordert haben, umfassen.

Abbildung 3.2 stellt graphisch den Zusammenhang zwischen einzelnen Bestellungen und einer aggregierten Betrachtung dar. Der linke Würfel zeigt die verschiedenen Kombinationen aus einem eindeutig identifizierbaren Kunden i , Produkt j und einer Bestellungseingangsstelle k . Jeder einzelne Teilwürfel enthält für einen Wunschliefzeitpunkt s und eine Vorlaufzeit e die Bestellmenge d_{ijkes} . Im rechten Graphen ist eine beliebige Aggregationsebene bestehend aus den Mengen I , J und K als grauer Teilwürfel exemplarisch hervorgehoben. Die in diesem Teilwürfel gelegenen Bestellmengen können vollständig zum Wert d_{IJKes} aufsummiert werden.

3.1.4. Zeitliche Dimensionierung

In der bisherigen Definition wurden Bestellungseingangs- und Wunschliefzeitpunkte verwendet, ohne deren Rahmen genauer zu definieren. Es ist zu klären, welche Aggregationsebene in einer zeitlichen Dimension betrachtet wird. Es muss eindeutig bestimmt




Abbildung 3.2.: Aggregation von Bestellmengen für vorgegebenes e und s

werden, welche diskreten Zeiträume bzw. Perioden hinter einem Bestellungseingangs- bzw. Wunschlieferzeitpunkt stehen, bspw. ein Tag, eine Kalenderwoche, ein Monat oder vielleicht sogar eine genaue Uhrzeit. Im bisherigen Beispiel eines Herstellers von Elektronikartikeln wurden stets Tage betrachtet - bspw. der 23. Oktober als Zeitpunkt des Bestellungseingangs.

Prinzipiell hat jeder diskrete Zeitraum eine bestimmte Länge. Durch die Aufzeichnungsgenauigkeit der Supply Chain ist die minimale Dauer eines solchen diskreten Zeitraums limitiert. Wird beispielsweise nur das Datum des Bestellungseingangs erfasst, dann können unterschiedliche Tageszeiten im verallgemeinerten Auftragsprofil nicht berücksichtigt werden. Wird zwar die genaue Stunde, nicht aber die Minute des Bestellungseingangs festgehalten, ist eine minutengenaue Betrachtung nicht möglich. Ausgehend von den aufgezeichneten Daten ist allerdings eine Aggregation zu länger andauernden Zeiträumen denkbar. Eine Woche besteht so beispielsweise aus sieben Tagen oder ein Quartal aus drei Monaten. Die Zusammenhänge und Einschränkungen werden hier kurz dargestellt. Sei t^* eine Periode mit der kürzesten Länge, die die Aufzeichnungsgenauigkeit der Supply Chain ermöglicht. Zur Vereinfachung sind diese Perioden beginnend mit einer zu bestimmenden Anfangsperiode der Reihe nach durchnummeriert (1, 2, 3 usw.). Soll jetzt ein verallgemeinertes Auftragsprofil mit längeren Perioden untersucht werden, müssen sich diese eindeutig aus den Aufzeichnungen der Supply Chain ableiten lassen. Dabei müssen sich alle nummerierten Perioden der kürzeren Länge eindeutig einer der ebenfalls durchnummerierten längeren Perioden zuordnen lassen. Ein einfaches Beispiel ist die Zuordnung von Tagen zu Wochen, wie in Abbildung 3.3 illustriert. Die eindeutige Zuordnung wird dabei durch die Formel $\lfloor \frac{t^*-1}{7} \rfloor + 1$ beschrieben.

Eine solche eindeutige Zuordnung ist allerdings nicht immer möglich. Ist die Länge beispielsweise durch die Aufzeichnungsgenauigkeit auf Wochen begrenzt, ist eine genaue Konvertierung auf Monatsbasis nicht möglich. Wie bereits von Kilger und Wagner (2008)




Abbildung 3.3.: Zuordnung von Tagen zu Wochen

dargestellt, kann eine Woche Teil von zwei Monaten sein, womit eine eindeutige Zuordnung nicht möglich ist. In Abbildung 3.4 teilen sich beispielhaft die Wochen 5 und 9 auf die Monate 1 und 2 bzw. 2 und 3 auf. Hier kann eine abschätzende Methode verwendet werden, die die Bestellungen auf die beiden Monate proportional verteilt.




Abbildung 3.4.: Zuordnung von Wochen zu Monaten

Die Analyse von längeren Zeiträumen kann als Aggregation in der zeitlichen Dimension angesehen werden. Die Bestellmengen für die längeren Zeiträume können einfach durch Addition der Mengen für die jeweils zugeordneten kürzeren Zeiträume berechnet werden. Im weiteren Verlauf der Untersuchungen wird davon ausgegangen, dass die Dauer der Perioden klar definiert und aus den aufgezeichneten Daten der Supply Chain eindeutig berechenbar ist. Ähnlich wie die Maßeinheit der Bestellmenge wird diese aber nicht mehr explizit ausgewiesen.

3.1.5. Einfluss der verwendeten Maßeinheit

Auch wenn die verwendete Maßeinheit hinter den Variablen nicht aufgeführt wird, hat sie einen signifikanten Effekt auf die resultierenden Bestellwerte. Ein einfaches Beispiel soll diesen Umstand verdeutlichen.

Gegeben sei ein beliebiger Getränkehersteller, der Limonade in 0,5l- und 1,5l-Flaschen abfüllt. Üblicherweise bestellen seine Kunden die großen Flaschen mit einer längeren Vorlaufzeit als die kleinen Flaschen. Der Getränkehersteller kann nun verkaufte Liter oder Flaschen seiner Limonade als Maßeinheit für das verallgemeinerte Auftragsprofil verwenden. Wie in Tabelle 3.1 dargestellt, kann dies zu signifikant unterschiedlichen Bestellverläufen führen. Der Händler verkauft in diesem Beispiel zu Vorlaufzeiten von $e = 3$ und $e = 2$ jeweils 100 1,5l-Flaschen und zu $e = 1$ und $e = 0$ jeweils 100 0,5l-Flaschen. Es werden so insgesamt 400 Flaschen bestellt, die sich gleichmäßig über die vier Vorlaufzeiten verteilen. Betrachtet der Händler allerdings die nachgefragten Liter seiner Limonade, so wird er feststellen, dass ein Großteil der Nachfrage auf die Vorlaufzeiten von $e = 3$ und $e = 2$ konzentriert ist. Zu jeder dieser Vorlaufzeiten werden 150 Liter bestellt, während bei den kürzeren Vorlaufzeiten nur 50 Liter verkauft werden.

D_{IJKes}	$e = 3$	$e = 2$	$e = 1$	$e = 0$
Verkaufte 0,5l-Flaschen	0	0	100	200
Verkaufte 1,5l-Flaschen	100	200	200	200
Verkaufte Flaschen	100	200	300	400
Verkaufte Liter	150	300	350	400

Tabelle 3.1.: Bestellmengen bei unterschiedlichen Maßeinheiten

Wie das einfache Beispiel verdeutlicht, können verschiedene Maßeinheiten zu fundamental unterschiedlichen Bestellverläufen führen. Deshalb ist eine klare Definition der verwendeten und für die Analyse relevanten Maßeinheit essentiell. ADI, die auf unterschiedlichen Maßeinheiten basieren, können nur gemeinsam verwendet werden, wenn klare Regeln für die Konvertierung der Bestellmengen zwischen den Maßeinheiten vorliegen.

3.1.6. Anteilige Bestellmengen

Bisher wurden einfache, kumulierte sowie ausstehende Bestellmengen betrachtet. Zusätzlich wird nun die anteilige Bestellmenge eingeführt. Sie beschreibt den Anteil der mit einer Vorlaufzeit von mindestens e eingegangenen Bestellmenge an der Gesamtnachfrage. Bestellt beispielsweise der Elektronikhändler *Jupiter* zum 30. November insgesamt 40.000 Radiowecker und sind 30 Tage zuvor 20.000 davon bestellt, dann beträgt die anteilige Bestellmenge für eine Vorlaufzeit von 30 Tagen 50%. Folgende neue Variable wird für die anteilige Bestellmenge eingeführt:

$X_{ijk es}$ Anteilig kumuliert vorliegende Bestellmenge eines Kunden i für Produkt j über Bestellungseingangsstelle k , eingegangen mit einer Vorlaufzeit von mindestens e und mit Wunschlieferszeitpunkt s .

Die anteilig vorliegende Bestellmenge kann durch die Division der zur Vorlaufzeit e vorliegenden Bestellmenge $D_{ijk es}$ durch die Gesamtnachfrage $D_{ijk 0s}$ berechnet werden. Es gilt also $X_{ijk es} = D_{ijk es} / D_{ijk 0s}$. Analog zu den bisherigen Variablen kann die anteilig vorliegende Bestellmenge auch für höhere Aggregationsebenen berechnet werden. Für eine beliebige Kundengruppe I , eine Produktgruppe J und eine Gruppe von Bestellungseingangsstellen K ist $X_{IJK es}$ die anteilig für den Wunschlieferszeitpunkt s zur Vorlaufzeit e vorliegende Bestellmenge. Die anteilige Bestellmenge ist natürlich nur für Wunschlieferszeitpunkte definiert, in denen positiv kumulierte Nachfrage auftritt, d. h. $D_{IJK 0s} > 0$ gilt.

3.1.7. Verwendung von aggregierten Informationen

In den bisherigen Ausführungen wurde die Aggregation von drei planungsrelevanten Objekten und in der zeitlichen Dimension betrachtet. Dabei wurden aggregierte Informationen ausschließlich aus der Summation von detaillierter vorliegenden Daten gewonnen. In der Praxis treten allerdings häufig Situationen auf, in denen die ADI ausschließlich auf einem aggregierten Niveau bereitsteht. Dies sind Bestellungen, bei denen Kunde,

Produkt, Bestellungseingangsstelle und Wunschlieferzeitpunkt nicht eindeutig zu identifizieren sind. Vielmehr sind nur Mengen von Kunden, Produkten und Bestellungseingangsstellen sowie ein Zeitraum für den Wunschliefertermin bekannt. Rahmenverträge, in denen sich die Kunden zu verbesserten Konditionen verpflichten, eine gewisse Produktmenge innerhalb eines festgeschriebenen Zeitraums abzunehmen, sind ein gutes Beispiel für solche Bestellungen. Die Informationen aus einem solchen Rahmenvertrag sollen der Supply Chain größere Planungssicherheit geben und können auch ex-post als ADI verwendet werden. So kann sich beispielsweise der Elektrohändler *Jupiter* verpflichten, im vierten Quartal des laufenden Jahres 200.000 Radiowecker unterschiedlichen Typs abzunehmen, wofür er 10% Rabatt auf den Einkaufspreis erhält. Die Menge der Kunden I enthält in diesem Beispiel mit *Jupiter* nur einen Kunden. Die Menge der Produkte J und der Bestellungseingangsstellen K umfasst allerdings mehrere Elemente. Die Menge J enthält alle Radiowecker und K besteht mangels genauerer Definition aus allen Bestellungseingangsstellen der Supply Chain. Die Wunschlieferzeitpunkte liegen zwischen dem 01. Oktober und 31. Dezember. Sie stehen also nicht auf Tages- oder Monatsbasis bereit. Entscheidend für die Einsetzbarkeit dieser ADI ist die damit verbundene Aggregationsebene, die durch die Mengen I , J und K sowie die Länge der betrachteten Zeiträume definiert ist. Bei der ex-post Analyse einer Aggregationsebene kann stets die ADI benutzt werden, deren Aggregationsebene in der zu untersuchenden enthalten ist. Wenn sich die für die Analyse relevante Aggregationsebene auf die Kundenmenge I' , Produktmenge J' und Bestellungseingangsstellen in K' bezieht, dann kann die ADI verwendet werden, deren entsprechenden Mengen I , J und K vollständig darin enthalten sind. Damit die ADI benutzt werden kann, muss also folgendes gelten: $I \subseteq I'$, $J \subseteq J'$ und $K \subseteq K'$. Bei der Aggregation in der zeitlichen Dimension muss es möglich sein, die Zeiträume, auf die sich die ADI bezieht, eindeutig einem einzigen für die Analyse relevanten Zeitraum zuzuordnen. Werden in der Analyse beispielsweise Informationen auf Tagesbasis untersucht und liegt die ADI nur auf Monatsbasis vor, kann die ADI nicht einfach benutzt werden, da ein Monat nicht eindeutig einem einzelnen Tag zuzuteilen ist. In der umgekehrten Situation wäre dies möglich, da jeder Tag eindeutig einem bestimmten Monat zugeordnet werden kann. Es können hier natürlich bestimmte Annahmen getroffen werden, um eine Disaggregation der auf Monatsbasis vorliegenden ADI auf Tagesbasis zu erlauben. So kann beispielsweise angenommen werden, dass die Bestellmengen über alle Tage des Monats gleichverteilt eingehen.

Diese Definition der einsetzbaren ADI verallgemeinert die vorherige Sichtweise, die Aggregation als reine Summation von ADI begriffen hat, die auf der granularsten Ebene vorlag. Diese ADI bezog sich auf Mengen I , J und K , die jeweils nur aus einem Element bestanden, und der betrachtete Zeitraum entsprach dem genauesten Wunschlieferzeitraum, den die Supply Chain aufnehmen konnte. Die neue Definition erweitert die Möglichkeiten der ADI-Nutzung um Bestellungen auf höheren Aggregationsebenen.

Die ADI auf einem aggregierten Niveau wird im Zeitverlauf immer genauer definiert und liegt irgendwann als exakt definierte Bestellung vor. Es ist wichtig zu beachten, dass die ADI auf einem aggregierten Niveau herausgerechnet werden muss, wenn diese mittlerweile durch konkrete Bestellungen substituiert wurde. Hat also *Jupiter* am 01. September 25.000 Radiowecker mit dem 15. Oktober als Wunschlieferzeitpunkt bestellt,

dann ist dieser Auftrag Teil des Rahmenvertrags und gleichzeitig eine vollständig definierte Bestellung. Die bestellten 25.000 Radiowecker wären von den 200.000 Radioweckern abzuziehen, und nur die verbleibende Menge von 175.000 Radioweckern dürfte als ADI aus dem Rahmenvertrag miteinbezogen werden. Die Gesamtmenge auf dem aggregierten Niveau bleibt mit 200.000 Stück dabei unverändert.

3.2. Durchschnittliches Bestellverhalten


Die Definitionen waren bisher auf das Bestellverhalten für einen einzelnen Wunschlieferszeitpunkt s fokussiert und entsprechend von diesem abhängig. Es sind allerdings Unterschiede zwischen Wunschlieferszeitpunkten zu erwarten. Rückschlüsse auf das Bestellverhalten der Kunden lassen sich deshalb bei der Betrachtung eines einzelnen Wunschlieferszeitpunkts nicht ziehen. Möglich wird dies durch die Betrachtung des durchschnittlichen Bestellverhaltens der Kunden, dessen ex-post Analyse der Schwerpunkt dieses Abschnitts ist.

Die Relevanz unterschiedlicher Aggregationsebenen und deren Erfassung durch das verallgemeinerte Auftragsprofil wurden diskutiert. Zur Vereinfachung der Darstellung wird künftig eine beliebige Aggregationsebene bestehend aus den drei Mengen I, J und K durch A abgekürzt. So wird statt der Variablen D_{IJKes} , U_{IJKes} und X_{IJKes} nun D_{Aes} , U_{Aes} und X_{Aes} verwendet.

Die folgenden Ausführungen beziehen sich auf eine beliebige für die Supply Chain relevante Aggregationsebene A. Es wird davon ausgegangen, dass die Maßeinheit der Bestellinformationen sowie die Aggregation in der zeitlichen Dimension klar definiert sind und durchgängig verwendet werden. Sie werden deshalb hier nicht mehr explizit aufgeführt. Ferner hat die Supply Chain die beschriebene ADI für einen Zeitraum erfasst und vorliegen, der mit dem Zeitpunkt t_1 beginnt. Der aktuelle Zeitpunkt sei t_n .

Um das Verständnis zu erleichtern, wird an dieser Stelle auf das Beispiel eines Herstellers von Elektronikartikeln aus dem letzten Abschnitt zurückgegriffen. Dieser möchte beispielhaft das Bestellverhalten seiner deutschen Kunden für alle Kaffeemaschinen unabhängig von der Bestellungseingangsstelle genauer untersuchen. Mit den Gruppen der Kunden, Produkte und Bestellungseingangsstellen ist die relevante Aggregationsebene hier klar definiert. Den Hersteller interessieren dabei die bestellten Stückzahlen auf Wochenbasis, womit die Maßeinheit der ADI und die Länge der Zeiträume festgelegt sind. Für diese Analyse stehen der Supply Chain die Informationen der vergangenen sechs Wochen zur Verfügung. Die Zeitpunkte t_1 und t_n stehen somit auch fest. Bei der Betrachtung der ADI für diese sechs Wochen kann sich für den Hersteller die in Abbildung 3.5 dargestellte Situation ergeben.

Die Bestellungsverläufe für die verschiedenen Wunschlieferszeitpunkte unterscheiden sich teilweise stark. Bei einer maximalen Vorlaufzeit von ebenfalls sechs Wochen konzentrieren sich beispielweise die Bestellungen für den Wunschlieferszeitpunkt t_1 auf drei bis vier Wochen Vorlaufzeit. Über 60% der Bestellungen für t_1 gehen zu dieser Vorlaufzeit ein. Eine andere Entwicklung ergibt sich für t_3 . Vorlaufzeitübergreifend hält sich die wöchentliche Bestellmenge konstant bei 180 Stück. Als drittes Beispiel ist die Entwicklung für

Abbildung 3.5.: ADI in Abhängigkeit von der Bestellvorlaufzeit e

t_5 zu beachten. Hier fällt die wöchentliche Bestellmenge mit sinkender Vorlaufzeit stetig ab. Es sind also höchst unterschiedliche Bestellentwicklungen zu beobachten.

Zu einer stärker komprimierten ex-post Charakterisierung des Bestellverhaltens müssen deshalb zeitübergreifende Durchschnittswerte berechnet werden. Für die dargestellte Stichprobe einfacher Bestellmengen kann mit den bekannten Formeln aus der Statistik⁴ das arithmetische Mittel für eine bestimmte Vorlaufzeit berechnet werden:

$\mu(t_1, t_n, d_{\text{Aes}})$ Arithmetisches Mittel der zur Vorlaufzeit e eingegangenen Bestellmenge auf der Aggregationsebene \mathbf{A} basierend auf einer Stichprobe von Wunschlieferszeitpunkten zwischen t_1 und t_n .

Es gilt

$$\mu(t_1, t_n, d_{\text{Aes}}) = \sum_{s=t_1}^{t_n} d_{\text{Aes}}/n \quad (3.2.1)$$

Analog ist dieser Wert für die kumuliert vorliegende, ausstehende und anteilig vorliegende Bestellmenge definiert. Dabei ist d_{Aes} durch D_{Aes} , U_{Aes} bzw. X_{Aes} zu ersetzen. Die entsprechenden arithmetischen Mittel sind dann $\mu(t_1, t_n, D_{\text{Aes}})$, $\mu(t_1, t_n, U_{\text{Aes}})$ bzw. $\mu(t_1, t_n, X_{\text{Aes}})$.

Neben dem arithmetischen Mittel ist die Standardabweichung der in der Stichprobe auftretenden Bestellmengen wichtig bei der Bewertung des Bestellverhaltens. Auch sie kann

⁴Vgl. bspw. Bley Müller u.a. (2002, S.13 ff.).

mit bekannten Formeln aus der Statistik berechnet werden.⁵

$\sigma(t_1, t_n, d_{\text{Aes}})$ Standardabweichung der zur Vorlaufzeit e eingegangenen Bestellmenge auf der Aggregationsebene A basierend auf einer Stichprobe von Wunschlieferszeitpunkten zwischen t_1 und t_n .

Es gilt

$$\sigma(t_1, t_n, d_{\text{Aes}}) = \sqrt{\sum_{m=t_1}^{t_n} (d_{\text{Aem}} - \mu(t_1, t_n, d_{\text{Aes}}))^2 / (n - 1)} \quad (3.2.2)$$

Wieder können die Standardabweichungen für die kumuliert vorliegende, ausstehende und anteilig vorliegende Bestellmenge $\sigma(t_1, t_n, D_{\text{Aes}})$, $\sigma(t_1, t_n, U_{\text{Aes}})$ bzw. $\sigma(t_1, t_n, X_{\text{Aes}})$ durch das Ersetzen von d_{Aes} berechnet werden.

Die ex-post Analyse dieser Werte erlaubt zeitübergreifende Rückschlüsse auf das durchschnittliche Bestellverhalten und dessen Konstanz. Während das arithmetische Mittel dabei das durchschnittliche Bestellverhalten beschreibt, dienen die Standardabweichungen als Indikator für die Konstanz. Diese Werte bilden gleichzeitig die Grundlage für die folgende Charakterisierung des Bestellverhaltens. In Tabelle 3.2 bis Tabelle 3.5 sind die Werte beispielhaft für die einfache, kumulierte, ausstehende und anteilige Bestellmenge aus Abbildung 3.5 berechnet.

Abbildung 3.6 stellt zusätzlich den Zusammenhang zwischen den einzelnen Bestellmengen und den Durchschnittswerten für die einfachen Bestellmengen graphisch dar. Dazu zeigt Abbildung 3.6 links die bereits in Abbildung 3.5 illustrierten Bestellmengen und rechts die dazugehörigen Durchschnittswerte pro Vorlaufzeit. Die grauen Boxen stellen die Höhe der Standardabweichungen von den in der Mitte gelegenen arithmetischen Mitteln dar. In diesem Beispiel gingen so bei Vorlaufzeiten von 3–4 Wochen die im Schnitt höchsten Bestellmengen ein. Allerdings unterlagen diese einer vergleichsweise starken Streuung.

⁵Vgl. bspw. Bleymüller u.a. (2002, S.19 ff.).

d_{Aes}	<i>Wunschlieferszeitpunkt</i>						$\mu(t_1, t_n, d_{\text{Aes}})$	$\sigma(t_1, t_n, d_{\text{Aes}})$
	t_1	t_2	t_3	t_4	t_5	t_6		
$e = 6$	100	50	180	0	250	150	121,7	90,6
$e = 5$	200	100	180	100	200	150	155,0	46,4
$e = 4$	400	300	180	200	150	250	246,7	92,0
$e = 3$	350	200	180	300	150	300	246,7	80,4
$e = 2$	100	200	180	150	100	150	146,7	40,8
$e = 1$	50	100	180	50	50	50	80,0	52,9
$e = 0$	0	0	0	0	0	0	0,0	0,0

Tabelle 3.2.: Berechnung arithmetisches Mittel und Standardabweichung für einfache Bestellmenge

3. Das verallgemeinerte Auftragsprofil

D_{Aes}	<i>Wunschlieferzeitpunkt</i>						$\mu(t_1, t_n, D_{\text{Aes}})$	$\sigma(t_1, t_n, D_{\text{Aes}})$
	t_1	t_2	t_3	t_4	t_5	t_6		
$e = 6$	100	50	180	0	250	150	121,7	90,6
$e = 5$	300	150	360	100	450	300	267,7	130,6
$e = 4$	700	450	540	300	600	550	523,3	136,6
$e = 3$	1050	650	720	600	750	850	770,0	161,9
$e = 2$	1150	850	900	750	850	1000	916,7	140,2
$e = 1$	1200	950	1080	800	900	1050	996,7	142,4
$e = 0$	1200	950	1080	800	900	1050	996,7	142,4

Tabelle 3.3.: Berechnung arithmetisches Mittel und Standardabweichung für kumuliert vorliegende Bestellmenge

U_{Aes}	<i>Wunschlieferzeitpunkt</i>						$\mu(t_1, t_n, U_{\text{Aes}})$	$\sigma(t_1, t_n, U_{\text{Aes}})$
	t_1	t_2	t_3	t_4	t_5	t_6		
$e = 6$	1100	900	900	800	650	900	875,0	147,5
$e = 5$	900	800	720	700	450	750	720,0	150,3
$e = 4$	500	500	540	500	300	500	473,3	86,4
$e = 3$	150	300	360	200	150	200	226,7	85,2
$e = 2$	50	100	180	50	50	50	80,0	52,9
$e = 1$	0	0	0	0	0	0	0,0	0,0
$e = 0$	0	0	0	0	0	0	0,0	0,0

Tabelle 3.4.: Berechnung arithmetisches Mittel und Standardabweichung für ausstehende Bestellmenge

X_{Aes}	<i>Wunschlieferzeitpunkt</i>						$\mu(t_1, t_n, X_{\text{Aes}})$	$\sigma(t_1, t_n, X_{\text{Aes}})$
	t_1	t_2	t_3	t_4	t_5	t_6		
$e = 6$	8,3	5,3	16,7	0,0	27,8	14,3	12,1	9,8
$e = 5$	25,0	15,8	33,3	12,5	50,0	28,6	27,5	13,5
$e = 4$	58,3	47,4	50,0	37,5	66,7	52,4	52,0	9,9
$e = 3$	87,5	68,4	66,7	75,0	83,3	81,0	77,0	8,4
$e = 2$	95,8	89,5	83,3	93,8	94,4	95,2	92,0	4,8
$e = 1$	100	100	100	100	100	100	100	0,0
$e = 0$	100	100	100	100	100	100	100	0,0

Tabelle 3.5.: Berechnung arithmetisches Mittel und Standardabweichung für anteilig vorliegende Bestellmenge (in %)




Abbildung 3.6.: Vergleich einzelner und durchschnittlicher Bestellwerte

So waren die Schwankungen bei den durchschnittlich niedrigeren Bestellmengen zu Vorlaufzeiten von 2 bzw. 5 Wochen deutlich geringer. Die gleiche Analyse kann analog für die kumuliert vorliegende, ausstehende und anteilige Bestellmenge durchgeführt werden. Aus Tabelle 3.3 und Tabelle 3.4 kann die durchschnittlich kumuliert vorliegende bzw. ausstehende Bestellmenge zu verschiedenen Vorlaufzeiten entnommen werden. So lagen beispielsweise 2 Wochen vor dem Wunschlieferttermin im Schnitt Bestellungen für 917 Kaffeemaschinen vor, während in der verbleibenden Zeit durchschnittlich nur noch Bestellungen für 80 Kaffeemaschinen eingingen. Damit lag 2 Wochen vor dem Wunschlieferttermin im Schnitt 92% der tatsächlichen Nachfrage vor, wie in Tabelle 3.5 aufgeführt ist. Die Schwankungen der ausstehenden bzw. anteilig vorliegenden Bestellungen waren dabei im Vergleich zu längeren Vorlaufzeiten deutlich geringer. So betrug die Standardabweichung für die ausstehende Bestellmenge nur 52,9 und für die anteilig vorliegende 4,8%. Die Streuung der kumuliert vorliegenden Bestellmengen ist dabei für Vorlaufzeiten von 5 und weniger Wochen mit über 130 im Vergleich zur ausstehenden Bestellmenge hoch.

Neben dem arithmetischen Mittel und der Standardabweichung kann der Variationskoeffizient ein wichtiges Maß für die ex-post Analyse der ADI sein. Er entspricht der Division der Standardabweichung durch das arithmetische Mittel und ist somit ein Maß für die relative Streuung der Bestellmenge. Entsprechend ist folgende Variable definiert:

$VK(t_1, t_n, d_{Aes})$ Variationskoeffizient der zur Vorlaufzeit e eingegangenen Bestellmenge auf der Aggregationsebene A basierend auf einer Stichprobe von Wunschlieferszeitpunkten zwischen t_1 und t_n .

	$VK(t_1, t_n, d_{Aes})$	$VK(t_1, t_n, D_{Aes})$	$VK(t_1, t_n, U_{Aes})$	$VK(t_1, t_n, X_{Aes})$
$e = 6$	74,5	74,5	16,9	81,2
$e = 5$	29,9	47,2	20,9	49,0
$e = 4$	37,3	26,1	18,3	19,0
$e = 3$	32,6	21,0	37,6	10,9
$e = 2$	27,8	15,3	66,1	5,2
$e = 1$	66,1	14,3		0,0
$e = 0$		14,3		0,0

Tabelle 3.6.: Variationskoeffizienten für Beispieldaten aus Tabelle 3.2 bis 3.5 (in %)

Es gilt

$$VK(t_1, t_n, d_{Aes}) = \sigma(t_1, t_n, d_{Aes}) / \mu(t_1, t_n, d_{Aes}) \quad (3.2.3)$$

Auch hier können die Variationskoeffizienten $VK(t_1, t_n, D_{Aes})$, $VK(t_1, t_n, U_{Aes})$ und $VK(t_1, t_n, X_{Aes})$ durch das Einfügen von D_{Aes} , U_{Aes} bzw. X_{Aes} für d_{Aes} bestimmt werden. Die Variationskoeffizienten für obiges Beispiel sind in Tabelle 3.6 aufgeführt. Dabei ist dieser nur definiert, wenn das arithmetische Mittel ungleich 0 ist.

Der Variationskoeffizient setzt die Standardabweichung ins Verhältnis zum arithmetischen Mittel. So beträgt beispielweise bei einer Vorlaufzeit von 2 Wochen der Variationskoeffizient der kumuliert vorliegenden Bestellmenge $140,2 / 916,7 = 15,3\%$. Die Standardabweichung der Bestellmenge betrug also $15,3\%$ der durchschnittlichen Bestellmenge.




Abbildung 3.7.: Vergleich diskreter und kontinuierlicher Betrachtung

Die bisher betrachteten Durchschnittswerte waren diskrete Werte bezogen auf eine bestimmte Vorlaufzeit. Für die folgenden Analysen und Darstellungen ist allerdings häufig eine kontinuierliche Betrachtung geeignet. Die Vorlaufzeit wird dabei nicht mehr als diskreter Zeitpunkt verstanden, sondern als ein kontinuierliches Zeitmaß. Abbildung 3.7 illustriert die diskrete und kontinuierliche Betrachtung und deren Zusammenhänge exemplarisch. Die Abbildungen zeigen die Durchschnittswerte und Standardabweichungen für die anteilig vorliegenden Bestellmengen. In der kontinuierlichen Darstellung sind das arithmetische Mittel und die Standardabweichung durch die durchgezogene bzw. gestrichelte Funktion gekennzeichnet. Sie durchlaufen idealtypisch wie dargestellt die Werte der diskreten Darstellung zu den entsprechenden Vorlaufzeiten.

Die kontinuierliche Darstellung ermöglicht eine komprimierte und kompaktere Beschreibung des Bestellverhaltens als die diskrete Form, da lediglich die Parameter der kontinuierlichen Funktion für die Charakterisierung notwendig sind. Vorgehensweisen zur Abschätzung von kontinuierlichen Funktionen werden im folgenden Kapitel 4 erläutert.

3.3. Zusammenfassung

Grundlage für das verallgemeinerte Auftragsprofil ist die strukturierte Erfassung von ADI. Die hierfür notwendigen Variablen wurden in Abschnitt 3.1 detailliert beschrieben. Sie bilden die Grundlage für die folgende Analyse der Daten. Wie das verallgemeinerte Auftragsprofil beziehen sich diese Variablen stets auf eine zu spezifizierende Aggregationsebene, die sich wiederum aus klar definierten Gruppen von Kunden, Produkten und Bestellungseingangsstellen zusammensetzt:

d_{Aes} Bestellmenge auf der Aggregationsebene **A** mit Vorlaufzeit e zu Wunschlieferszeitpunkt s

Für die folgenden Analysen ebenfalls von großem Interesse sind die kumulierten, ausstehenden und anteilig vorliegenden Bestellmengen. Hierfür wurden folgende Variablen definiert:

D_{Aes} Kumuliert vorliegende Bestellmenge auf der Aggregationsebene **A** mit Vorlaufzeit e zu Wunschlieferszeitpunkt s

U_{Aes} Zur Vorlaufzeit e noch ausstehende Bestellmenge auf der Aggregationsebene **A** mit Wunschlieferszeitpunkt s

X_{Aes} Anteilig vorliegende Bestellmenge auf der Aggregationsebene **A** mit Vorlaufzeit e zu Wunschlieferszeitpunkt s

Der Einfluss unterschiedlicher Aggregationsebenen auf das verallgemeinerte Auftragsprofil wurde diskutiert. Es wurde dargestellt, wie obige Werte berechnet werden können und was dabei beachtet werden muss. Ebenfalls untersucht wurden die Bedeutung und Zusammenhänge verschiedener Maßeinheiten sowie unterschiedlicher Längen in den betrachteten Zeiträumen. Die Wichtigkeit einer klaren Definition der verwendeten Maßeinheit und betrachteten Zeitraumlänge wurde hervorgehoben, auch wenn die Werte in den definierten Variablen nicht explizit aufgeführt werden.

In Abschnitt 3.2 wurden verschiedene Maße zur Bewertung des durchschnittlichen Bestellverhaltens eingeführt. Alle diese Werte definieren ein vollständiges verallgemeinertes Auftragsprofil. Das arithmetische Mittel dient dabei der Einschätzung des zeitübergreifenden durchschnittlichen Verhaltens. Zur Beurteilung der Konstanz dieses Verhaltens wurden die Standardabweichung und der Variationskoeffizient definiert. Für die kumuliert vorliegende Bestellmenge D_{Aes} und einen Betrachtungszeitraum zwischen t_1 und t_n sind dies folgende Werte:

- Arithmetisches Mittel: $\mu(t_1, t_n, D_{Aes})$
- Standardabweichung: $\sigma(t_1, t_n, D_{Aes})$
- Variationskoeffizient: $VK(t_1, t_n, D_{Aes})$

Im Vergleich zu Meyr (2003) ist die explizite Betrachtung unterschiedlicher Aggregationsebenen eine wesentliche Erweiterung bei der Verwendung von Auftragsprofilen. Dies geschah insbesondere vor dem Hintergrund, dass für Supply Chains bei ihren Planungsaufgaben unterschiedlichste Aggregationsebenen relevant sein können. Dabei wurde zu Beginn die einzelne Bestellung bewusst als Ausgangsbasis gewählt, um eine unternehmensübergreifende strukturierte Erfassung von Bestellungsinformationen für deren anschließende Aufbereitung und Analyse zu fördern. Die Definition der ADI wurde später auf beliebige Aggregationsebenen erweitert. Die Berücksichtigung unterschiedlicher Zeitraumlängen und verschiedener Maßeinheiten sind als weitere Neuerungen zu nennen.

4. Grundlagen der Zeitreihen- und Regressionsanalyse

Zur Errechnung der Kennzahlen, die das Bestellverhalten charakterisieren, werden Methoden aus der Zeitreihen- und Regressionsanalyse benötigt, die in diesem Kapitel vorgestellt werden. Die meisten dieser Vorgehensweisen wurden für unterschiedliche Prognosemethoden entwickelt. Entsprechend dem Fokus dieser Arbeit können sie auch für eine reine ex-post Analyse von Daten verwendet werden. Im Unterschied zur Prognose werden die ex-post analysierten Informationen nicht in die Zukunft projiziert, um zukünftige Werte vorherzusagen.

Es folgt zunächst eine Einführung in die Zeitreihen- und Regressionsanalyse in den Abschnitten 4.1 und 4.2. Danach werden in Abschnitt 4.3 auch die Probleme diskutiert, die sich bei Autokorrelation und Heteroskedastizität ergeben. Ergänzend wird in Abschnitt 4.4 eine Übersicht zu aktuellen *Curve Fitting*-Methoden gegeben.

4.1. Zeitreihenanalyse

Die hier vorgestellten Methoden sind den zahlreichen Veröffentlichungen zur Zeitreihenanalyse entnommen. Beispielhaft seien hierzu Hartung u.a. (1998, S. 637–744), Silver u.a. (1998, S. 74–146), Schröder (2005), Tempelmeier (2008, S. 31–98) sowie Meyr (2008, 2012) genannt. Die Darstellung bezieht sich auf den ex-post zu analysierenden Zeitraum zwischen den beliebigen Zeitpunkten t_1 und t_n . Für diesen Zeitraum wurden die zu untersuchenden Werte y_1 bis y_n ermittelt. Dabei ist y_m der beobachtete Wert für den Zeitpunkt t_m . Abbildung 4.1 stellt eine solche Zeitreihe beispielhaft dar. Die auf der y -Achse abgetragenen zu untersuchenden Werte sollen in diesem Beispiel eine beliebige nicht genauer definierte Nachfrage repräsentieren.




Abbildung 4.1.: Beispiel Zeitreihe




Abbildung 4.2.: Unterschiedliche Zeitreihen

Es werden nun zunächst verschiedene Modelle vorgestellt, mit denen unterschiedliche Zeitreihen beschrieben werden können. Anschließend werden Verfahren erläutert, die die Ausprägung dieser Modelle für eine konkrete Zeitreihe abschätzen und aktualisieren. Dem folgt eine kurze Darstellung der Besonderheiten von sporadischen Zeitreihen.

4.1.1. Unterschiedliche Zeitreihenmodelle

Aufgabe der Zeitreihenanalyse ist es, den Verlauf der y -Werte durch ein mathematisches Modell möglichst genau abzubilden. Dabei werden anfangs häufig drei einfache Modelle unterschieden:

1. Modell konstanter Nachfrage
2. Modell einer Zeitreihe mit Trend
3. Modell einer Zeitreihe mit Saisonalitäten

Abbildung 4.2 zeigt diese drei Situationen beispielhaft. Die im linken Graphen dargestellte Zeitreihe entspricht der aus Abbildung 4.1. Es handelt sich um eine konstante Zeitreihe. Das bedeutet, dass die Nachfrage bis auf zufällige und identisch unabhängig verteilte Abweichungen¹ einen konstanten Wert δ annimmt. Wenn ε_m diese zufällige Abweichung zum Zeitpunkt t_m ist, spiegelt folgendes Modell diese Situation wider:

$$y_m = \delta + \varepsilon_m \quad (4.1.1)$$

Der mittlere Graph zeigt eine Nachfragesituation, die einen positiven Trend aufweist: Die Nachfrage nimmt mit der Zeit zu. Mathematisch kann diese Situation durch folgendes Modell dargestellt werden:

¹Die durchschnittliche Abweichung ist 0.

$$y_m = \beta_0 + \beta_1 \cdot m + \varepsilon_m \quad (4.1.2)$$

β_0 steht dabei für den Schnittpunkt der Trendgeraden mit der y -Achse, β_1 ist die Steigung der Geraden. Im Fall eines positiven Trends, wie im Graphen dargestellt, gilt $\beta_1 > 0$. Umgekehrt ist bei fallender Nachfrage, also einem negativen Trend, $\beta_1 < 0$. Durch die Multiplikation mit m in der Gleichung wird der Einfluss des Trends über den Zeitverlauf berücksichtigt. Wie bereits beim Modell konstanter Nachfrage steht ε_m für die verbleibende zufällige und identisch unabhängig verteilte Abweichung der Nachfragewerte.

Die verbleibende dritte Situation im rechten Graphen zeigt wiederkehrende saisonale Schwankungen in der Nachfrage. Diese Saisonalitäten können durch folgendes Modell abgebildet werden:

$$y_m = \delta \cdot \zeta_h + \varepsilon_m \quad (4.1.3)$$

Das Modell ähnelt dem für die konstante Nachfrage, ist allerdings um den Faktor ζ_h erweitert worden. Dieser soll die saisonalen Aspekte in der Gleichung widerspiegeln. Wie im Graphen dargestellt, zeichnet sich Saisonalität durch wiederkehrende Schwankungen innerhalb eines fixen Zeitrahmens aus. Häufig sind solche Schwankungen auf jährlicher Basis zu beobachten, wenn die Umsätze innerhalb der „Saison“ steigen und anschließend wieder fallen. Allgemein wird ein fixer Zeitrahmen betrachtet, der sich in H Zeitabschnitte aufteilen lässt, im Fall des Kalenderjahres beispielsweise in vier Quartale oder zwölf Monate. Der Faktor $\zeta_h \geq 0$ repräsentiert den saisonalen Einfluss für den h -ten Zeitabschnitt, dabei gilt für umsatzstarke Zeitpunkte $\zeta_h > 1$, umgekehrt für schwache Zeitpunkte $\zeta_h < 1$. In der dargestellten Modellgleichung wird davon ausgegangen, dass der Zeitpunkt t_m in einen solchen h -ten Zeitabschnitt fällt. ε_m steht abermals für die verbleibenden zufälligen Abweichungen, die in der idealisierten Situation in Abbildung 4.2 allerdings 0 betragen, weil alle Ausprägungen auf der Modellkurve selbst liegen.

Die Zeitreihenanalyse unterscheidet zusätzlich häufig noch zwischen Saisonalitäten und Zyklen. Letztere stellen dabei längerfristige Auf- und Abwärtsschwankungen dar, die sich über mehrere Jahre erstrecken können.

In den bisher beschriebenen Situationen wurde davon ausgegangen, dass der zu untersuchenden Zeitreihe exklusiv ein Trend, eine Saisonalität oder ein Zyklus zugrunde liegt. In der Realität gibt es allerdings häufig Situationen, in denen mehrere dieser Eigenschaften parallel auftreten. Abbildung 4.3 illustriert beispielhaft zwei solcher Zeitreihen, die Trend und Saisonalität auf unterschiedliche Art kombinieren.

Im linken Graphen sind Trend und Saisonalität additiv verknüpft. Das entsprechende Modell kann die Form

$$y_m = \beta_0 + \beta_1 \cdot m + \delta \cdot \zeta_h + \varepsilon_m \quad (4.1.4)$$




Abbildung 4.3.: Kombination von Trend und Saisonalität

haben. Der Einfluss der Trendkomponente wird dabei durch $\beta_0 + \beta_1 \cdot m$ widerspiegelt, während die saisonale Komponente durch $\delta \cdot \zeta_h$ in das Modell einfließt. Hervorzuheben ist, dass der Trend keinen direkten Einfluss auf die Höhe der saisonalen Schwankungen hat. Die Werte werden addiert. Hier unterscheidet sich die andere im rechten Graphen dargestellte Zeitreihe. Die Höhe der saisonalen Schwankungen nimmt im Zeitverlauf zu. Zur Modellierung dieser Zeitreihe ist deshalb eine multiplikative Verknüpfung von Trend und Saisonalität besser geeignet. Sie kann die Form

$$y_m = (\beta_0 + \beta_1 \cdot m) \cdot \zeta_h + \varepsilon_m \quad (4.1.5)$$

haben. Da die Trendkomponente $\beta_0 + \beta_1 \cdot m$ im obigen Beispiel im Zeitverlauf größer wird, verursacht die Multiplikation mit ζ_h zunehmend stärkere saisonale Schwankungen. Je nach vorliegender Zeitreihe können verschiedene Formen der Modellierung geeignet sein. Die vier Komponenten

- Trend
- Saisonalität
- Zyklus und
- zufällige Abweichung

können entsprechend in der Zeitreihenanalyse beliebig additiv, multiplikativ oder anderweitig kombiniert werden.

4.1.2. Berechnungsverfahren

Nach der Wahl eines Modells bietet die Zeitreihenanalyse zahlreiche Methoden zur Berechnung der Parameter für eine vorliegende Zeitreihe. Die Parameter der im vorherigen Abschnitt vorgestellten Modelle sind sämtliche Werte, die sich nicht auf einen spezifischen Zeitpunkt m beziehen, sondern der übergreifenden Modellierung der Zeitreihe dienen. Beim Modell der konstanten Zeitreihe ist dies beispielsweise das arithmetische Mittel δ , bei der Zeitreihe mit Trend sind es β_0 und β_1 . Ziel der Methoden zur Parameterbestimmung ist es, die zufälligen Abweichungen im Modell zu minimieren. Dies gelingt häufig durch die Minimierung der quadrierten Abweichungen. Als Maßeinheit wird oft der *mean square error* (MSE) eingesetzt, der deren Durchschnitt wiedergibt: $MSE = \frac{1}{n} \sum_{i=1}^n (\varepsilon_i)^2$. Für das Modell der konstanten Zeitreihe kann bewiesen werden, dass der MSE minimiert wird, wenn δ dem arithmetischen Mittel der beobachteten Werte entspricht:²

$$\delta = \frac{1}{n} \sum_{i=1}^n y_i \quad (4.1.6)$$

Bei einer Zeitreihe mit Trend kann analog gezeigt werden, dass der MSE durch den Einsatz folgender Gleichungen minimiert wird:³

$$\beta_0 = \frac{\sum_{i=1}^n i^2 \sum_{i=1}^n y_i - \sum_{i=1}^n i \sum_{i=1}^n i \cdot y_i}{n \sum_{i=1}^n i^2 - \left(\sum_{i=1}^n i \right)^2} \quad (4.1.7)$$

$$\beta_1 = \frac{n \sum_{i=1}^n i \cdot y_i - \sum_{i=1}^n i \sum_{i=1}^n y_i}{n \sum_{i=1}^n i^2 - \left(\sum_{i=1}^n i \right)^2} \quad (4.1.8)$$

Die Methoden für die Berechnung saisonaler Schwankungen bzw. kombinierter Modelle werden hier nicht im Detail vorgestellt, da sie im weiteren Verlauf nicht wieder aufgegriffen werden. Die Vorgehensweisen sind teilweise deutlich komplexer. Die Ratio-to-Moving-Average-Methode von Macaulay (1931) sei trotzdem beispielhaft genannt. Sie gehört mit zu den grundlegenden in diesem Bereich. Sie wurde ursprünglich für ein Modell mit multiplikativer Verknüpfung der verschiedenen Komponenten einer Zeitreihe entwickelt. Die Methode trennt die Saison- und Trendkomponente der Zeitreihe, um sie separat zu berechnen. Eine übersichtliche Darstellung der Vorgehensweise unter Einbeziehung von Zykluseinflüssen findet sich in Tempelmeier (2008, S. 69ff.). Zahlreiche Arbeiten basie-

²Zu dem Beweis vgl. u.a. Tempelmeier (2008, S. 40 ff.).

³Zu dem Beweis vgl. u.a. Tempelmeier (2008, S. 50 ff.).




Abbildung 4.4.: Einsatz verschiedener Zeitreihenmodelle

ren auf den Ideen von Macaulay (1931) und enthalten deutlich komplexere Modelle zur Berücksichtigung von Saisonalität, so unter anderem die Arbeit von Shiskin u.a. (1967). Vor der Auswahl des einzusetzenden Berechnungsverfahrens ist allerdings die Entscheidung für das richtige Zeitreihenmodell ein wichtiger Schritt. Bei der Wahl eines unangemessenen Modells liefert auch das beste Berechnungsverfahren suboptimale Ergebnisse. Es besteht natürlich die Möglichkeit, ein Modell zu wählen, das alle Eventualitäten eines Zeitreihenverlaufs berücksichtigt. Allerdings steigt damit, wie angedeutet, die Komplexität des zu nutzenden Berechnungsverfahrens. Bei der Wahl eines aufwendigeren Modells sollte deshalb der Zugewinn an Genauigkeit gegen die zusätzliche Komplexität abgewogen werden.

Was die Wahl eines ungeeigneten Modells bewirken kann, verdeutlicht Abbildung 4.4. Beide Graphen enthalten die durch Punkte gekennzeichnete Zeitreihe mit einem Trend, die bereits in Abbildung 4.2 abgebildet wurde. In den beiden Darstellungen wurde versucht, die Zeitreihe durch verschiedene Modelle darzustellen. Im linken Graphen wurde das Modell einer konstanten Nachfrage eingesetzt und im rechten das Modell, das einen Trend berücksichtigt. Zur Berechnung wurden die vorgestellten Gleichungen verwendet. Die schwarzen Linien markieren die modellierten Zeitreihen. Es ist leicht zu erkennen, dass die einzelnen Werte im rechten Graphen näher an der Modellgeraden liegen als im linken Graphen. Die verbleibenden Abweichungen sind bei diesem Zeitreihenmodell also deutlich geringer. Die absoluten Werte dieser Abweichungen sind in den Graphen als dunkle Kreuze aufgeführt. Obwohl also für beide Modelle ein Berechnungsverfahren gewählt wurde, das den MSE minimiert, erklärt das im rechten Graphen verwendete Modell die Zeitreihe deutlich besser und genauer.

Umgekehrt kann auch ein komplexeres Modell benutzt werden, als der Zeitreihe angemessen ist. Es wurde beispielsweise ein Trendmodell eingesetzt, obwohl gar kein Trend vorliegt. Um zu überprüfen, ob das angenommene Modell adäquat ist, können statistische Testverfahren durchgeführt werden. Für den beschriebenen Fall des Einsatzes eines

Trendmodells in einer Situation ohne Trend wird hier exemplarisch ein Student-t-Test vorgestellt. Die Student-t-Verteilung, auf der der Test basiert, wurde erstmalig 1908 von W.S. Gosset unter dem Pseudonym Student veröffentlicht.⁴

Falls kein Trend vorhanden ist, sollte die Trendgerade eine Steigung von 0 haben. Der Student-t-Test prüft, ob die für eine beliebige Zeitreihe berechnete Trendsteigung mit einer zu bestimmenden Wahrscheinlichkeit 0 sein kann oder signifikant davon abweicht.⁵ Die Wahrscheinlichkeit wird als Signifikanzniveau des Tests bezeichnet. Sollte der Test nicht ausschließen, dass die Steigung 0 sein kann, kann darauf geschlossen werden, dass eventuell kein Trend vorhanden ist.

Der Test setzt sich aus folgenden Schritten zusammen:

1. Bestimmen des Signifikanzniveaus α
2. Berechnen der Student-t-verteilten Testgröße $T = \beta_1/s_{\beta_1}$. Dabei ist s_{β_1} die Standardabweichung der Trendsteigung, also die zu erwartende Streuung von β_1 , wenn sie auf Basis der vorliegenden Zeitreihe wie in Formel 4.1.8 beschrieben berechnet wurde. Es gilt

$$s_{\beta_1} = \sqrt{\frac{\sum_{i=1}^n (\varepsilon_i)^2}{(n-2) \sum_{i=1}^n \left(\frac{n+1}{2} - i\right)^2}} \quad (4.1.9)$$

3. Bestimmen des Wertes $t = t_{1-\alpha/2; n-2}$, den eine Student-t-Verteilung mit $n-2$ -Freiheitsgraden mit einer Wahrscheinlichkeit von $1-\alpha/2$ nicht überschreitet. Der Wert kann den verbreiteten Tabellen zur Student-t-Verteilung entnommen werden.⁶
4. Wenn $-t \leq T \leq t$, dann ist nicht auszuschließen, dass die Steigung der Trendgeraden 0 ist. In diesem Fall kann die Annahme getroffen werden, dass kein Trend vorliegt. Andernfalls weicht β_1 signifikant von 0 ab und die Hypothese, dass die Trendsteigung 0 ist, ist zu verwerfen.

Aus den dargestellten Gründen sollte eine Zeitreihe genau untersucht werden, bevor ein Modell ausgewählt und berechnet wird. Die Wahl des Modells ist entsprechend ein wichtiger Schritt jeder Zeitreihenanalyse.

4.1.3. Aktualisierung der Modelle

Mit dem Voranschreiten der Zeit treten neue Werte auf. Im Beispiel aus dem letzten Abschnitt sind das die Werte y_{n+1}, y_{n+2}, \dots zu den Zeitpunkten t_{n+1}, t_{n+2}, \dots . Wenn eine Supply Chain diese Werte in die ex-post Analyse miteinbeziehen will, bestehen zwei Möglichkeiten:

⁴Vgl. Box (1987) zur Geschichte der Veröffentlichung und Student (1908a,b) zur eigentlichen Veröffentlichung.

⁵Vgl. Bley Müller u.a. (2002, S. 151–152).

⁶Vgl. beispielsweise Pearson und Hartley (1976a, S. 138–146).

1. Die vollständige Neuberechnung der Werte
2. Die Aktualisierung der Werte

Das Vorgehen bei der ersten Variante ist selbsterklärend. Zur Aktualisierung der Werte existieren allerdings spezielle Verfahren. Das ursprünglich von Holt (1957)⁷ und Brown (1959) vorgestellte Verfahren der exponentiellen Glättung wird hier erläutert.

Es wird zunächst die einfache exponentielle Glättung am Beispiel des arithmetischen Mittels als Durchschnittswert dargestellt. Sei hierzu \bar{y}_n das zum Zeitpunkt t_n berechnete arithmetische Mittel. Zum Zeitpunkt t_{n+1} ist nun der Wert y_{n+1} eingegangen. Durch den Einsatz von Gleichung 4.1.10 wird der Durchschnittswert exponentiell geglättet:

$$\bar{y}_{n+1} = \alpha \cdot y_{n+1} + (1 - \alpha) \bar{y}_n \quad (4.1.10)$$

In den aktualisierten Wert fließt also der alte Wert mit einer Gewichtung von $(1 - \alpha)$ und die neue Beobachtung mit einem Gewicht von α ein. Dabei ist der Parameter $0 < \alpha < 1$ durch den Anwender zu bestimmen. Tempelmeier (2008, S. 48) schreibt, dass in der Praxis häufig Werte zwischen 0,1 und 0,3 für α geeignet sind. Meyr (2003) verwendet diese Werte auch im Zusammenhang mit dem Auftragsprofil.

In Tabelle 4.1 ist für eine Beispielzeitreihe der Durchschnittswert exponentiell geglättet worden. Zu t_5 wurde das arithmetische Mittel mit $\bar{y}_5 = 100$ berechnet. Die neue Beobachtung zum Zeitpunkt t_6 beträgt $y_6 = 110$. Der exponentiell geglättete Durchschnittswert für drei unterschiedliche α -Werte findet sich in den letzten drei Spalten der Tabelle. So beträgt für $\alpha = 0,1$ der aktualisierte Durchschnittswert 101.

y_1	y_2	y_3	y_4	y_5	\bar{y}_5	y_6	\bar{y}_6		
							$\alpha = 0,1$	$\alpha = 0,2$	$\alpha = 0,3$
100	90	95	110	105	100	110	101	102	103

Tabelle 4.1.: Beispiel exponentieller Glättung für arithmetisches Mittel

Allgemein wird das hier dargestellte Vorgehen als einfache exponentielle Glättung bzw. exponentielle Glättung erster Ordnung bezeichnet. Zur Berechnung eines beliebigen Wertes H_{n+1} werden der vorherige Wert H_n mit dem Faktor $(1 - \alpha)$ und die neu einfließende Beobachtung h_{n+1} mit α multipliziert und anschließend summiert: $H_{n+1} = \alpha \cdot h_{n+1} + (1 - \alpha) H_n$.

Entsprechend kann auch die Varianz einer Stichprobe geglättet werden. Wenn $\sigma_{y,n}^2$ die Varianz zum Zeitpunkt t_n ist, schlagen Bretschneider (1986) und Taylor (2006) hierfür folgende Gleichung vor:

$$\sigma_{y,n+1}^2 = \alpha \cdot (y_{n+1} - \bar{y}_n)^2 + (1 - \alpha) \sigma_{y,n}^2 \quad (4.1.11)$$

⁷Ein Nachdruck findet sich in Holt (2004).

Der alte Wert $\sigma_{y,n}^2$ fließt mit einer Gewichtung von $(1 - \alpha)$ ein, während der neue Wert $(y_{n+1} - \bar{y}_n)^2$ mit α multipliziert wird. Als neuer Wert wird $(y_{n+1} - \bar{y}_n)^2$ statt y_{n+1} verwendet, weil für die Varianz als Streuungsmaß die quadrierte Abweichung vom arithmetischen Mittel relevant ist. Die entsprechenden Werte für das Beispiel aus Tabelle 4.1 sind in Tabelle 4.2 aufgeführt.

$\sigma_{y,5}^2$	$y_6 - \bar{y}_5$	$\sigma_{y,6}^2$		
		$\alpha = 0,1$	$\alpha = 0,2$	$\alpha = 0,3$
62,5	10	66,25	70	73,75

Tabelle 4.2.: Beispiel exponentieller Glättung für Varianz

Ähnlich verhält es sich für die Kovarianz zwischen zwei Zeitreihen. Zusätzlich zu der hier bereits beispielhaft verwendeten Zeitreihe von y -Werten sei eine zweite Zeitreihe betrachtet, die zum Zeitpunkt t_m den Wert x_m annimmt. Die korrigierte Stichprobenkovarianz zwischen den Zeitreihen über den Zeitraum von t_1 bis t_n kann mit den bekannten Formeln aus der Statistik berechnet werden:⁸

$$CoV_n(x, y) = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n) \cdot (y_i - \bar{y}_n) \quad (4.1.12)$$

Gemäß den Ausführungen von RiskMetrics (1996, S. 83) und Taylor (2006) kann die Kovarianz zum Zeitpunkt t_{n+1} mit den neuen Beobachtungen x_{n+1} und y_{n+1} folgendermaßen geglättet werden:

$$CoV_{n+1}(x, y) = \alpha \cdot (x_{n+1} - \bar{x}_n) \cdot (y_{n+1} - \bar{y}_n) + (1 - \alpha) \cdot CoV_n(x, y) \quad (4.1.13)$$

Auch hier wird der Wert des vergangenen Zeitpunkts mit $(1 - \alpha)$ multipliziert. Als neuer Wert wird das für die Kovarianz relevante $(x_{n+1} - \bar{x}_n) \cdot (y_{n+1} - \bar{y}_n)$ mit α gewichtet. In Tabelle 4.3 ist eine zweite Zeitreihe dargestellt, um beispielhaft die exponentielle Glättung einer Kovarianz vorzuführen. Zum Zeitpunkt t_5 betrug die Stichprobenkovarianz zwischen den zwei Zeitreihen $CoV_5(x, y) = 50$. Nach Eingang der beiden neuen Werte $x_6 = 165$ und $y_6 = 110$ ergibt die exponentielle Glättung für $\alpha = 0,1$ eine Kovarianz von $CoV_6(x, y) = 60$.

	t_1	t_2	t_3	t_4	t_5	CoV_5	t_6	$x_{n+1} - \bar{x}_n$	$y_{n+1} - \bar{y}_n$	CoV_6 $\alpha = 0,1$
x_m	150	145	140	155	160	50	165	15	10	60
y_m	100	90	95	110	105		110			

Tabelle 4.3.: Beispiel exponentieller Glättung für Kovarianz

⁸Vgl. bspw. Ramanathan (2002, S. 38–39), \bar{x}_n ist das arithmetische Mittel der Zeitreihe von x -Werten.

Die einfache exponentielle Glättung wird, wie bereits gesagt, auch als exponentielle Glättung erster Ordnung bezeichnet. Brown und Meyer (1961) führten zusätzlich die exponentielle Glättung höherer Ordnung ein. Sie eignet sich unter anderem für Zeitreihen, die einem Trend unterliegen. Die Details der exponentiellen Glättung höherer Ordnung oder andere Verfahren werden hier nicht vorgestellt, da sie im weiteren Verlauf nicht relevant sind. Trotzdem sei auf einen umfangreichen Überblick zu exponentiellen Glättungsverfahren für die unterschiedlichsten Zeitreihenmodelle verwiesen. Er findet sich in Gardner (1985) und in einer überarbeiteten Version in Gardner (2006).

4.1.4. Besonderheiten sporadischen Bedarfs

Eine besondere Art der Zeitreihe ist die des sporadischen Bedarfs. Für ihre Analyse wurden spezielle Verfahren entwickelt. Dieser Abschnitt soll hierzu einen kurzen Überblick geben.

Es existieren unterschiedliche Definitionen für die Situation sporadischen Bedarfs. Nowack (2005) stellt einige davon vor. In Wedekind (1968) wird eine qualitative Definition präsentiert. Sporadischer Bedarf zeichnet sich für ihn durch Nachfrage aus, die auf wenige Zeitpunkte beschränkt ist. Zu einem Großteil der Zeitpunkte existiert kein Bedarf, während zu den verbleibenden Zeitpunkten größere Nachfragemengen zu beobachten sind. Abbildung 4.5 stellt diese Situation exemplarisch dar. Nur in drei von zwölf Zeitabschnitten (t_3 , t_5 , t_{11}) ist Nachfrage aufgetreten. Die Nachfrage kann also als sporadisch bezeichnet werden.




Abbildung 4.5.: Situation sporadischen Bedarfs

Die bisher vorgestellten Zeitreihenmodelle eignen sich nur bedingt zur Abbildung dieser Situation. Silver u.a. (1998, S. 127ff.), Nowack (2005) sowie Tempelmeier (2008, S. 86ff.) haben dies für die Verfahren der exponentiellen Glättung festgestellt. In Abbildung 4.5 ist als schwarze Linie das arithmetische Mittel der Nachfrage über die zwölf Zeitpunkte aufgeführt. Dieses war das vorgestellte Berechnungsverfahren für das Zeitreihenmodell konstanter Nachfrage. Für die Beispielsituation sporadischer Nachfrage scheint das Modell allerdings ungeeignet. In den neun Zeitabschnitten, in denen keine Nachfrage auftritt, nimmt das arithmetische Mittel einen positiven Wert an, der den nicht vorhandenen Be-

darf systematisch übersteigt. Im Gegensatz dazu ist das arithmetische Mittel für die drei Perioden, in denen Nachfrage auftritt, deutlich zu niedrig angesetzt. Andere Modelle aus der beschriebenen klassischen Zeitreihenanalyse sind in dieser Situation ebenfalls ungeeignet.

Da die Situation sporadischer Nachfrage in der Praxis keine Besonderheit ist, wurden zahlreiche Prognosemethoden dafür entwickelt. Diese Methoden beinhalten spezielle Modelle, um die Situation besser zu reflektieren. Eine der ersten Methoden stammt von Croston (1972) und wurde von Rao (1973) weiterentwickelt. Croston (1972) geht in einem ersten Modell von einer Situation mit fixer Nachfrage aus, die in einem gleichbleibenden Intervall wiederkehrt. In der Zeit dazwischen ist keine Nachfrage vorhanden. Er entwirft anschließend noch ein weiteres stochastisches Modell, bei dem das Auftreten von Nachfrage als Bernoulli-verteilt betrachtet wird. Das heißt, mit einer bestimmten Wahrscheinlichkeit ist zu einem Zeitpunkt Nachfrage bzw. keine Nachfrage zu erwarten. Für die gegebenenfalls auftretende Nachfragemenge wird eine Normalverteilung zugrunde gelegt. Rao (1973) korrigiert und verfeinert dieses Modell. Ein Beispiel für eine andere stochastische Modellierung findet sich in Johnston und Boylan (1996). Zusätzlich sei noch van Donselaar u.a. (2001) erwähnt. Ihre Arbeit fokussiert sich auf das Lagerhaltungsproblem in einer Situation, in der regelmäßig kleinere Bedarfsmengen auftreten, zu der sporadisch größere Nachfragemengen hinzukommen. Besonders interessant ist dabei der von van Donselaar u.a. (2001) miteinbezogene Aspekt von ADI.

4.2. Regressionsanalyse

Wie in der Zeitreihenanalyse wurde ein Großteil der Methoden aus der Regressionsanalyse zur Prognose künftiger Werte entwickelt. Dabei soll der Zusammenhang zwischen einer Menge unabhängiger Werte und einem abhängigen Wert genutzt werden, um Letzteren zu prognostizieren. Die Regressionsanalyse soll den Einfluss der unabhängigen Werte auf den abhängigen bestimmen. Ein häufig verwendetes Beispiel für eine Regressionsanalyse stammt aus dem Eiscremegeschäft. Die Annahme für diese Regression ist, dass ein starker Zusammenhang zwischen der Außentemperatur und der Nachfrage nach Eiscreme besteht. Dabei kann umso mehr Eiscreme verkauft werden, je wärmer es draußen ist. Vergangenheitswerte zur Außentemperatur und dem damit verbundenen Eiscremeumsatz werden zur Abschätzung des Zusammenhangs genutzt. Daten aus der Wetterprognose werden dann verwendet, um den Eiscremeumsatz der kommenden Tage zu prognostizieren.

Der Zusammenhang zwischen unabhängigen und abhängigen Werten wird auch als Korrelation bezeichnet. Wichtig für die Regressionsanalyse ist die Stärke dieser Korrelation. In diesem Abschnitt liegt das Augenmerk auf einer reinen ex-post Beurteilung. Der ermittelte Zusammenhang wird also nicht zur Prognose verwendet. Des Weiteren liegt hier der Fokus auf der einfachen linearen Regression. Einführungen dazu finden sich unter anderem in Makridakis und Wheelwright (1989, S. 159ff.), Makridakis u.a. (1998, S. 185ff.), Hartung u.a. (1998, S. 569–608) sowie Ramanathan (2002, S. 76ff.). Die folgenden Ausführungen zur linearen Regression können unter anderem ihnen entnommen werden.




Abbildung 4.6.: Beispiel einfache lineare Regression

Die einfache lineare Regression ist auf einen einzigen unabhängigen Wert begrenzt, wie im Eiscremebeispiel, das als einzigen unabhängigen Wert die Außentemperatur benutzt. Andere Formen der Regression betrachten Kombinationen von unabhängigen Werten, also zum Beispiel im Fall des Eiscremegeschäfts die Abhängigkeit des Umsatzes sowohl von der Außentemperatur als auch der Niederschlagsmenge. Des Weiteren ist die einfache lineare Regression auf Zusammenhänge beschränkt, die sich durch einfache lineare Gleichungen darstellen lassen. Abbildung 4.6 illustriert einen solchen Fall. Die Punkte markieren die Beobachtungskombinationen aus unabhängigen und dazugehörigen abhängigen Werten. Die n -te Beobachtung, bestehend aus dem unabhängigen Wert x_n und dem abhängigen Wert y_n , ist hervorgehoben in der Abbildung. Die Gerade markiert eine mögliche lineare Gleichung, um den Zusammenhang zwischen x - und y -Werten zu modellieren.

Die Beziehung zwischen x - und y -Werten kann allgemein für eine beliebige n -te Beobachtungskombination durch eine Modellgleichung folgender Form beschrieben werden:

$$y_n = \beta_0 + \beta_1 \cdot x_n + \varepsilon_n \quad (4.2.1)$$

Wie bei dem Zeitreihenmodell mit Trend beschreibt β_0 den y -Achsenabschnitt der Trendgeraden, β_1 die Steigung der linearen Regressionsgleichung und ε_n die verbleibende zufällige und identisch unabhängig verteilte Abweichung. Um den Einfluss des unabhängigen Werts zu berücksichtigen, wird β_1 im Gegensatz zur Zeitreihenanalyse mit x_n und nicht dem relevanten Zeitpunkt multipliziert.

Zur Berechnung von β_0 und β_1 für eine beliebige Stichprobe existiert ein Verfahren, das

x_1	x_2	x_3	x_4	x_5	\bar{x}	σ_x^2	$CoV(x, y)$	β_0	β_1
10	30	25	60	50	35	400			
y_1	y_2	y_3	y_4	y_5	\bar{y}	σ_y^2	200	10	0,5
15	25	22,5	40	35	27,5	100			

Tabelle 4.4.: Beispiel Regressionsanalyse

den bereits im Abschnitt 4.1.2 zur Zeitreihenanalyse beschriebenen MSE minimiert.⁹ Für die allgemeine Darstellung des Verfahrens wird hier eine beliebige Situation betrachtet, die aus N Beobachtungskombinationen von x - und y -Werten besteht. Diese seien $(x_1, y_1); \dots; (x_N, y_N)$. Die Gleichungen zur Berechnung sind

$$\beta_0 = \bar{y} - \beta_1 \cdot \bar{x} \quad (4.2.2)$$

und

$$\beta_1 = \frac{CoV(x, y)}{\sigma_x^2} = \frac{\sum_{i=1}^N (x_i - \bar{x}) \cdot (y_i - \bar{y})}{\sum_{i=1}^N (x_i - \bar{x})^2}. \quad (4.2.3)$$

\bar{x} und \bar{y} sind die arithmetischen Mittel für die N vorliegenden x - bzw. y -Werte. σ_x^2 ist die Varianz über die x -Werte und $CoV(x, y)$ die Kovarianz zwischen den x - bzw. y -Werten. In Tabelle 4.4 werden die Werte beispielhaft für eine aus 5 Beobachtungskombinationen bestehende Stichprobe berechnet. Die resultierende Regressionsgleichung lautet $y_n = 10 + 1/2 \cdot x_n + \varepsilon_n$.

Ein mögliches Maß für die bereits erwähnte Stärke der Korrelation ist der Korrelationskoeffizient R_{xy} . Er ist ein Maß für den durch die Regression erklärten Teil der abhängigen Werte. Er kann durch folgende Gleichung berechnet werden:

$$R_{xy} = \frac{CoV(x, y)}{\sigma_x \cdot \sigma_y} \quad (4.2.4)$$

Dabei gilt $R_{xy} \in [-1, 1]$. Häufig betrachtet wird auch der quadrierte Wert $R_{xy}^2 \in [0, 1]$. Je näher dieser dem Wert 1 kommt, desto stärker wird die Korrelation zwischen x - und y -Werten eingeschätzt.

In Abbildung 4.7 sind drei Situationen unterschiedlicher Korrelationsstärke dargestellt. Der linke Graph zeigt den Fall einer perfekten Korrelation. Die abhängigen Werte werden vollständig durch die unabhängigen erklärt. Der abhängige Wert kann in diesem Fall durch die Regressionsgerade genau berechnet werden. Es gibt keine Abweichungen von der Geraden und alle ε_n sind 0. Es gilt $R_{xy}^2 = 1$. Gleiches gilt für das Beispiel aus Tabelle 4.4: $R_{xy}^2 = \left(\frac{200}{20 \cdot 10}\right)^2 = 1$. Im Gegensatz dazu steht der rechte Graph. Die x - und y -Werte sind unkorreliert. Es besteht also kein Zusammenhang, der sich durch eine

⁹Vgl. bspw. Ramanathan (2002, S. 76ff.).




Abbildung 4.7.: Situationen unterschiedlicher Korrelationsstärke

lineare Regression erklären lässt. Dabei ist $R^2_{xy} = 0$. Der mittlere Graph stellt zusätzlich einen zwischen diesen beiden Extremen liegenden Fall dar, in dem die abhängigen Werte teilweise durch die Ausprägungen der unabhängigen Werte zu erklären sind. Es verbleiben aber Abweichungen von der Regressionsgeraden und es gilt $0 < R^2_{xy} < 1$.

Neben dem einfachen linearen existieren weitere teilweise aufwendige Regressionsverfahren. Sie berücksichtigen unter anderem mehrere unabhängige Werte und identifizieren auch nichtlineare Korrelationen. Es sei unter anderem auf Makridakis und Wheelwright (1989), Makridakis u.a. (1998) und Ramanathan (2002) sowie Abschnitt 4.4 zum Curve Fitting verwiesen.

4.3. Autokorrelation und Heteroskedastizität

Bislang unerwähnt blieben die Probleme, die sich beim Vorliegen von Autokorrelation oder Heteroskedastizität ergeben. In einer solchen Situation sind die vorgestellten Methoden zur Berechnung von Trend- und Regressionsgeraden nicht mehr effizient. Es sind dann andere Methoden zu verwenden, die die sich ergebenden Probleme berücksichtigen. Deshalb werden an dieser Stelle die Eigenheiten von Autokorrelation (Abschnitt 4.3.1) und Heteroskedastizität (Abschnitt 4.3.2) kurz erläutert.¹⁰ Dabei wird unter anderem auf Tests verwiesen, um eine mögliche Autokorrelation oder Heteroskedastizität zu identifizieren.

¹⁰Ramanathan (2002, S. 344ff.) stellt sowohl die Autokorrelation als auch die Heteroskedastizität detailliert dar. Die Ausführungen in diesem Abschnitt basieren auf diesen Beschreibungen.

4.3.1. Autokorrelation

Wenn Autokorrelation vorliegt, ist die Grundannahme der Unabhängigkeit der zufälligen Abweichungen ε_m verletzt. Diese Annahme ist allerdings in das Berechnungsverfahren für eine Trend- bzw. Regressionsgerade mit eingeflossen. Deswegen sind solche Verfahren bei Vorliegen von Autokorrelation ineffizient.

Autokorrelation liegt vor, wenn die zufällige Abweichung ε_m zum Zeitpunkt t_m von vorherigen Abweichungen abhängig ist. Es liegt also eine Korrelation mit vergangenen Werten vor. Die einfachste Form ist die Autokorrelation ersten Grades. Sie liegt vor, wenn die m -te Abweichung ε_m von der des unmittelbar vorherigen Zeitpunkts ε_{m-1} abhängig ist. Autokorrelation ersten Grades bedeutet, dass sich die Abweichungen durch eine Gleichung der Form

$$\varepsilon_m = \delta \cdot \varepsilon_{m-1} + \eta_m \quad (4.3.1)$$

darstellen lassen. Im Fall von Autokorrelation ist $\delta \neq 0$, wobei $-1 < \delta < 1$.¹¹ η_m ist die verbleibende Abweichung, die nicht durch die Autokorrelation zu erklären ist.

Abbildung 4.8 zeigt eine Situation mit Autokorrelation ersten Grades. Die Werte alternieren um die berechnete Trendgerade. In dem Beispiel liegt δ nahe -1.

Bei einer Autokorrelation k -ten Grades ist die Abweichung ε_m nicht nur von der letzten, sondern den k -letzten Abweichungen ε_{m-k} bis ε_{m-1} abhängig. Für ε_m kann also folgende Gleichung aufgestellt werden:

$$\varepsilon_m = \sum_{i=1}^k \delta_i \cdot \varepsilon_{m-i} + \eta_m \quad (4.3.2)$$

Zu Identifikation von Autokorrelation in einer Zeitreihe existieren statistische Tests. Wie von Ramanathan (2002, S. 386ff.) beschrieben, kann zur Feststellung von Autokorrelation 1. Grades der Durbin-Watson-Test¹², für k -ten Grades der Breusch-Godfrey-Test¹³ verwendet werden.

¹¹Vgl. bspw. Ramanathan (2002, S. 382).

¹²Vgl. Durbin und Watson (1950, 1951).

¹³Vgl. Breusch (1979); Godfrey (1978, 1996).




Abbildung 4.8.: Beispiel Autokorrelation 1. Grades

Bereits Ramanathan (2002, S. 389ff.) hat festgestellt, dass es kein Verfahren gibt, das die Beseitigung einer Autokorrelation garantieren kann. Wie von Hendry und Mizon (1978) diskutiert, ist die Autokorrelation oft durch die Wahl des falschen Zeitreihenmodells bedingt. In diesem Zusammenhang werden von Ramanathan (2002, S. 389ff.) das Verfahren von Cochrane und Orcutt (1949) sowie das Verfahren von Hildreth und Lu (1960) zur Bestimmung eines geeigneten Modells dargestellt. Diese werden allerdings aufgrund ihrer Komplexität hier nicht detailliert erläutert.

4.3.2. Heteroskedastizität

Heteroskedastizität kann sowohl im Rahmen der Regressions- als auch der Zeitreihenanalyse auftreten. Sie liegt vor, wenn die Streuung des abhängigen Werts durch den unabhängigen Wert bedingt ist. Abbildung 4.9 stellt eine solche Situation dar, in der die Streuung des abhängigen Werts mit steigendem unabhängigen Wert wächst.

In der Zeitreihenanalyse bedeutet Heteroskedastizität, dass die Streuung des zu untersuchenden Werts vom betrachteten Zeitpunkt abhängig ist. Dies ist beispielsweise der Fall, wenn die Streuung mit voranschreitender Zeit zu- oder auch abnimmt.

Zur Feststellung von Heteroskedastizität wurden zahlreiche statistische Tests entwickelt. Ramanathan (2002, S. 347 ff.) nennt hier unter anderem die Tests von Park und von Glejser, den Breusch-Pagan-Test sowie den White-Test.¹⁴

Ähnlich wie bei der Autokorrelation ist bei Vorliegen von Heteroskedastizität die Grundannahme verletzt, dass die Abweichungen unabhängig und identisch verteilt sind. Die

¹⁴Vgl. Park (1966), Glejser (1969), Breusch und Pagan (1979) sowie White (1980).




Abbildung 4.9.: Beispiel Heteroskedastizität

dargestellten Methoden zur Abschätzung einer Regressionsgeraden bzw. einer Trendgeraden sind dann nicht mehr effizient. Ramanathan (2002, S. 355ff.) stellt einige alternative Verfahren vor, die in dieser Situation besser geeignet sind.

4.4. Curve Fitting

Als weitere Modellierungsmöglichkeit aus der Zeitreihen- und Regressionsanalyse existieren die Methoden des Curve Fittings. Das Curve Fitting wird unter anderem von Levenberg (1944), Marquardt (1963), Moré (1978), Cleveland (1979), Cleveland und Devlin (1988), Nocedal und Wright (2006, S. 245–269) sowie Dalgaard (2008, S. 275–288) vorgestellt. Die Ausführungen in diesem Abschnitt basieren auf diesen Arbeiten. Am Beispiel in Abbildung 4.10 wird dieses Verfahren exemplarisch dargestellt. Analog zum Beispiel in Abbildung 4.6 sind die Beobachtungskombinationen in diesem zweidimensionalen Beispiel durch einen unabhängigen und einen abhängigen Wert definiert. Die n -te Beobachtung besteht dabei wieder aus dem unabhängigen Wert u_n und dem abhängigen Wert v_n . Für das Curve Fitting ist nun eine Funktion f auszuwählen, deren Parameter anschließend sukzessiv kalibriert bzw. „gefittet“ werden, um den Datensatz möglichst genau widerzuspiegeln.¹⁵ Die Abweichungen der Beobachtungskombinationen von der resultierenden Funktion sollen also möglichst gering sein.

¹⁵Dies muss nicht zwangsläufig eine lineare Gleichung wie in der linearen Regressionsanalyse in Abschnitt 4.2 sein, sondern kann eine beliebige Funktion f sein.




Abbildung 4.10.: Beispiel-Datensatz für das Curve Fitting

Für das Curve Fitting-Beispiel in Abbildung 4.10 wird exemplarisch die Verteilungsfunktion der Normalverteilung $f(\mathbf{u}|\mu, \sigma) = \int_{-\infty}^u \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{-\frac{1}{2}\left(\frac{t-\mu}{\sigma}\right)^2} dt$ benutzt. Die Wahl einer geeigneten Funktion ist zwar nicht trivial, sie wird aber hier als gegeben angenommen. Die Parameter dieser Funktion sind μ und σ . In Abbildung 4.11 sind verschiedene Varianten dieser Funktion f mit unterschiedlichen Parameterwerten dargestellt. Im linken Graphen sind zwei Normalverteilungsfunktionen dargestellt, die den Datensatz nicht einwandfrei widerspiegeln. In einem Fall ist der Erwartungswert μ zu niedrig angesetzt, wodurch die Funktion bereits für niedrigere unabhängige Werte stärker ansteigt, als dies im Datensatz der Fall ist. Im anderen Beispiel ist die Standardabweichung σ zu hoch. Der Anstieg der Funktion ist dadurch stärker als notwendig in die Breite gezogen. Im rechten Graph ist die an den Datensatz angepasste Normalverteilungsfunktion eingebettet.

Abstrahierend von diesem Beispiel wird beim Curve Fitting ein Datensatz bestehend aus Beobachtungskombinationen unabhängiger Werte \mathbf{x}^T und eines abhängigen Wertes y betrachtet. Dabei sind die unabhängigen Werte nicht wie im Beispiel zwangsläufig eindimensional. Wenn beispielsweise m unabhängige Werte in die Funktion einfließen, werden diese durch den Vektor $\mathbf{x}^T = (x_1, \dots, x_m)$ dargestellt. Für die weitere Darstellung des Curve Fittings wird verallgemeinernd davon ausgegangen, dass der relevante Datensatz aus N Beobachtungskombinationen unabhängiger Werte \mathbf{x}^T und eines abhängigen Wertes y besteht. Die j -te Beobachtungskombination setzt sich dabei aus dem Vektor unabhängiger Werte $\mathbf{x}_j^T = (x_{j1}, \dots, x_{jm})$ und dem dazugehörigen abhängigen Wert y_j zusammen. Der betrachtete Datensatz besteht also aus den Beobachtungskombinationen $(\mathbf{x}_1^T, y_1); \dots; (\mathbf{x}_N^T, y_N)$.

Ziel des Curve Fitting ist es, die Parameter der Funktion f so abzustimmen, dass die Abweichungen der N Beobachtungskombinationen von der Funktion möglichst gering sind. Für die j -te Beobachtungskombination wird diese Abweichung durch die Variable ε_j erfasst. Dabei seien die Parameter der beliebigen Funktion f in dem Parametervektor




Abbildung 4.11.: Einsatz des Curve Fittings beim Beispiel-Datensatz

\mathbf{w} enthalten. Wenn die Funktion f durch k Parameter definiert wird, gilt $\mathbf{w} = (w_1, \dots, w_k)$, wobei w_l der l -te Parameter der Funktion ist. Für die Funktion $f(\mathbf{x}^T | \mathbf{w} = (a, b, c)) = a \cdot e^x + b \cdot x^2 + c$ besteht der Vektor \mathbf{w} beispielsweise aus den drei Parametern a , b und c . Bei der Verteilungsfunktion der Normalverteilung im vorherigen Beispiel ist $\mathbf{w} = (\mu, \sigma)$. Die beim Curve Fitting zu minimierenden Abweichungen der Beobachtungskombinationen von der Funktion sind nun wie folgt definiert: $\varepsilon_j = f(\mathbf{x}_j^T | \mathbf{w}) - y_j$.

Zwei wesentliche Vorgehensweisen sind bei Curve Fitting-Methoden zu unterscheiden:

1. *Least Squares-Schätzungen* (LSS)
2. *Maximum Likelihood-Schätzungen* (MLS)

Bei LSS versucht die Curve Fitting-Methode den $MSE = \frac{1}{N} \sum_{i=1}^N (\varepsilon_i)^2$ zu minimieren. Der Marquardt-Levenberg-Algorithmus ist eine LSS-basierte Curve Fitting-Methode.¹⁶ Er ist eine Weiterentwicklung des Gauss-Newton-Verfahrens.¹⁷ Der Algorithmus verfolgt für eine durch den Nutzer zu spezifizierende Funktion f eine iterative Optimierung der Funktionsparameter in \mathbf{w} . Ziel des Verfahrens ist dabei die schrittweise Minimierung des MSE. Hinweise und weiterführende Ideen zur Implementierung des Marquardt-Levenberg-Algorithmus finden sich in Moré (1978) und Nocedal und Wright (2006, S. 245–269). Weitere Beispiele für LSS-Curve Fitting-Methoden finden sich in Fletcher und Xu (1987) sowie Gill und Murray (1978). Die von Cleveland (1979) sowie Cleveland und Devlin (1988) entwickelte Locally Weighted Regression oder LOESS nutzt die Vorgehensweise der MSE-Minimierung ebenfalls.

Die MLS bestimmen hingegen denjenigen Parametersatz \mathbf{w} , für den das Eintreten des beobachteten Datensatzes aus x -Vektoren und y -Werten am wahrscheinlichsten ist. An-

¹⁶Vgl. zu diesem Algorithmus Levenberg (1944) und Marquardt (1963).

¹⁷Zum Gauss-Newton-Verfahren vgl. u.a. Nocedal und Wright (2006, S. 245–269).

ders ausgedrückt: Für gegebene x -Vektoren und y -Werte wird das \mathbf{w} gesucht, das die Likelihood-Funktion $L(\mathbf{w}|\mathbf{x}^T, y)$ maximiert. Die Likelihood-Funktion ist eine „Umkehrung“ der Funktion f . Die x -Vektoren und y -Werte sind als gegeben eingesetzt und die Parameter in \mathbf{w} als Variablen zu optimieren. Myung (2003) enthält eine Einführung zu MLS. Amemiya (1977) und Johansen und Juselius (1990) sind zwei Beispiele für Veröffentlichungen, in denen MLS-Verfahren entwickelt und vorgestellt werden.

Das einzusetzende Curve Fitting-Verfahren muss der Anwender situationsbedingt auswählen. Die Details der Verfahren werden hier nicht erläutert, da eine solche Beschreibung sehr umfangreich ist und für die folgenden Analysen eine geringe Relevanz hat. Die Verfahren sind außerdem bereits in zahlreiche Computerprogramme integriert. Die Marquardt-Levenberg-Methode ist beispielsweise in Matlab, Mathematica und Origin umgesetzt.¹⁸ Zusätzlich gibt es für die genannten Programme Implementierungen von LOESS. Dalgaard (2008, S. 275–288) beschreibt eine Implementierung von Curve Fitting-Methoden in dem Statistikprogramm R.

Die Wahl der anzupassenden Funktion f obliegt bei den beschriebenen Methoden dem Anwender. Um zu untersuchen, ob eine Funktion überhaupt geeignet ist, einen Datensatz zu repräsentieren, existieren einige statistische Tests. So kann u.a. mit den Tests von Jarque und Bera,¹⁹ Shapiro und Wilk (1965) sowie Shapiro und Francia (1972) überprüft werden, ob ein Datensatz unabhängig von arithmetischem Mittel und Standardabweichung normalverteilt ist. Um zu testen, ob eine beliebige vollständig spezifizierte Funktion geeignet ist, einen Datensatz darzustellen, können u.a. der Chi-Quadrat-Anpassungstest, der Kolmogorov-Smirnov-Anpassungstest oder der Test von Anderson und Darling (1952) verwendet werden.²⁰ Ein solcher Test kann nach dem Curve Fitting durchgeführt werden, um die tatsächliche Eignung der angepassten Funktion für den vorliegenden Fall zu beurteilen.

¹⁸Zu Matlab siehe <http://de.mathworks.com/products/curvefitting/features.html>, zu Mathematica siehe <http://www.wolfram.com/products/applications/eda/features.html> und zu Origin siehe <http://cloud.originlab.com/pdfs/FeatureList91.pdf> (Stand: 01.10.2015)

¹⁹Zum Test von Jarque und Bera vgl. Jarque und Bera (1980, 1987) sowie Bera und Jarque (1981).

²⁰Zum Chi-Quadrat- und Kolmogorov-Smirnov-Anpassungstest vgl. u.a. Bley Müller u.a. (2002, S. 127ff.).

5. Charakterisierung des Bestellverhaltens

Das in Kapitel 3 definierte verallgemeinerte Auftragsprofil ist die Grundlage für das in diesem Kapitel vorgestellte Kennzahlensystem zur Charakterisierung und Bewertung des Bestellverhaltens in einer Supply Chain. Die bisher in Kapitel 3 eingeführten Werte beziehen sich stets auf eine bestimmte Vorlaufzeit. Entsprechend sind umso mehr Werte zur Erfassung der ADI notwendig, je länger der Vorlaufzeitrahmen des Bestellungseingangs ist. Die Kennzahlen in diesem Kapitel sollen eine kompaktere Einschätzung des Bestellverhaltens ermöglichen. Sie sollen nicht auf eine bestimmte Vorlaufzeit begrenzt sein, sondern eine vorlaufzeitübergreifende Beurteilung erlauben. Die einzelnen Kennzahlen beziehen sich dabei auf verschiedene Aspekte des Bestellverhaltens. Wie die Analysen in den Kapiteln 6 bis 8 zeigen, sind diese Aspekte für die Bestimmung des Entkopplungspunkts sowie die Prognose der zukünftigen Nachfrage von großer Bedeutung. Die Verwendung der Kennzahlen ist allerdings nicht auf diese Planungsaufgaben begrenzt. Sie können zur einfachen und schnellen Beurteilung der Einsetzbarkeit der ADI für die verschiedensten Planungsaufgaben im Supply Chain Management benutzt werden.¹

Abschnitt 5.1 beschäftigt sich zunächst mit der ex-post Untersuchung des statischen Bestellverhaltens. Die Kennzahlen sind hier auf das Vorlaufzeitfenster des Bestellungseingangs sowie die Streuung und Korrelation im Bestellverhalten fokussiert. Diese statischen Kennzahlen beruhen auf der Annahme, dass sich das Bestellverhalten im ex-post betrachteten Zeitraum nicht verändert hat. Es wird bei der Berechnung der verschiedenen Kennzahlen entsprechend davon ausgegangen, dass die jeweils zugrunde liegenden Zeitreihen bis auf zufällige Abweichungen konstant sind. Eine Veränderung des Bestellverhaltens in dem ex-post betrachteten Zeitraum wird durch diese Kennzahlen nicht erkannt und bewertet. Deshalb werden im anschließenden Abschnitt 5.2 zur Charakterisierung einer ex-post zu beobachtenden Veränderung des Bestellverhaltens die dynamischen Kennzahlen definiert. Während sich die Kennzahlen in den Abschnitten 5.1 und 5.2 auf Streuung und Korrelation im Bestellverhalten konzentrieren, werden in Abschnitt 5.3 zusätzliche Kennzahlen definiert, die bestimmte Annahmen überprüfen, auf denen das verallgemeinerte Auftragsprofil basiert. Wie in Kapitel 3 dargestellt, werden für das verallgemeinerte Auftragsprofil verschiedene Durchschnittswerte berechnet. Mit der Verwendung dieser Durchschnittswerte ist allerdings die Annahme verbunden, dass die zugrunde liegenden Zeitreihen zwischen den Wunschlieferzeitpunkten t_1 und t_n bis auf zufällig und identisch unabhängig verteilte Abweichungen konstant sind, wie den Ausführungen in Kapitel 4 zu

¹Ein Überblick der unterschiedlichen Planungsaufgaben im Supply Chain Management wurde in Kapitel 2 präsentiert.

entnehmen ist. Die Korrektheit dieser Annahme wird durch die Kennzahlen in Abschnitt 5.3 bewertet. Verschiedene Ausprägungen der Kennzahlen werden für mehrere Beispiele in Abschnitt 5.4 vorgestellt. In Abschnitt 5.5 wird die Möglichkeit eines Einsatzes von *Curve Fitting*-Methoden bei der Charakterisierung und Bewertung des Bestellverhaltens untersucht. Die Ergebnisse werden abschließend in Abschnitt 5.6 zusammengefasst.

5.1. Charakterisierung eines statischen Bestellverhaltens

Das Kennzahlensystem zum statischen Bestellverhalten ist in vier Bereiche unterteilt, wie




Abbildung 5.1.: Einordnung Kennzahlen zum Bestellverhalten

in Abbildung 5.1 illustriert. Im Einzelnen sollen die Kennzahlen folgende Eigenschaften des Bestellungseingangs ex-post charakterisieren:

1. **Spannweite**: Kennzahlen für die Länge bzw. Dauer des Bestellungseingangs
2. **Durchschnittliche Streuung**: Kennzahlen zur vorlaufzeitübergreifenden Durchschnittsstreuung im farblich hervorgehobenen Bereich der Bestellungseingänge
3. **Form der Streuung**: Kennzahlen zur Charakterisierung des Streuungsverlaufs über unterschiedliche Vorlaufzeiten
4. **Korrelation**: Vorlaufzeitübergreifende Kennzahlen zur Stärke der Korrelation zwischen vorliegenden Bestellmengen und der tatsächlich auftretenden Nachfrage

Die Kennzahlen werden nun detailliert beschrieben und definiert. Zur Darstellung der verschiedenen Kennzahlen wird K_Q als Abkürzung verwendet. Der Index Q spezifiziert

dabei die jeweilige Art der Kennzahl. Dem K_Q folgen in Klammern die für die Definition der jeweiligen Kennzahl relevanten Parameter.

5.1.1. Spannweite

Drei wesentliche Kennzahlen umfasst der Bereich zur Spannweite, wie in Abbildung 5.2 dargestellt. Sie beschreiben den Zeitrahmen des Bestellungseingangs. Die Kennzahlen ermöglichen der Supply Chain die ex-post Identifikation der relevanten Vorlaufzeiten für ihre Bestellungen und erlauben eine Nutzung für zukünftige Planungsaufgaben.




Abbildung 5.2.: Kennzahlen zur Spannweite

Die Grenzen dieses Rahmens sind durch einen Anfangs- und einen Endpunkt markiert. Der Anfangspunkt e_{start} gibt die längste Vorlaufzeit e an, zu der alle Bestellungen eingegangen waren. Das bedeutet, dass zur Vorlaufzeit e_{start} stets die gesamte Bestellmenge vorlag. Es gilt also für alle $e \leq e_{start}$: $\mu(t_1, t_n, X_{Aes}) = 100\%$. Dies impliziert, dass bei kürzeren Vorlaufzeiten keine Streuung mehr in der anteilig vorliegenden Bestellmenge aufgetreten ist, also $\sigma(t_1, t_n, X_{Aes}) = 0\%$ gilt. Die Bedeutung von t_1 und t_n ist dabei die gleiche wie im letzten Kapitel. Die Supply Chain hat die hier charakterisierte ADI seit t_1 aufgezeichnet, und t_n ist der aktuelle Zeitpunkt.

Der Endpunkt e_{end} beschreibt ergänzend die kürzeste Vorlaufzeit e , bis zu der keine längerfristigen Bestellungen eingegangen waren. Zu einer längeren Vorlaufzeit lagen somit nie Bestellungen vor. So gilt für alle $e > e_{end}$: $\mu(t_1, t_n, X_{Aes}) = 0\%$. Wie beim Anfangspunkt ist entsprechend keine Streuung in der anteilig vorliegenden Bestellmenge vorhanden: $\sigma(t_1, t_n, X_{Aes}) = 0\%$.

Als dritte Kennzahl gibt die eigentliche Spannweite die Dauer des gesamten Bestellungseingangs an. Sie entspricht der Zeitdauer zwischen End- und Anfangspunkt. Die Spannweite ist somit über die Differenz dieser Punkte definiert.

Zur Kennzeichnung der drei Werte wird als Index der Kennzahl für den Anfangspunkt 1, *Start*, für den Endpunkt 1, *End* und für die Spannweite 1, *Range* benutzt. Die drei Kennzahlen sind entsprechend wie folgt definiert:

- Anfangspunkt: $K_{1,Start}(t_1, t_n, \mathbf{A}) = e_{start}$
- Endpunkt: $K_{1,End}(t_1, t_n, \mathbf{A}) = e_{end}$
- Spannweite: $K_{1,Range}(t_1, t_n, \mathbf{A}) = e_{end} - e_{start} + 1$

Alle Werte sind abhängig von der jeweils betrachteten Aggregationsebene \mathbf{A} . Für eine andere Aggregationsebene mit anderen Kunden, Produkten oder Bestellungseingangsstellen kann selbstverständlich ein anderes Bestellverhalten auftreten. Neben der Aggregationsebene ist der analysierte Zeitrahmen relevant. Dieser beginnt mit t_1 und endet zum aktuellen Zeitpunkt t_n . Für einen anderen Zeitrahmen sind natürlich auch hier andere Kennzahlenwerte möglich, da sich das Bestellverhalten verändern kann.

Die präsentierten Definitionen von Anfangs- und Endpunkt sowie Spannweite beziehen sich auf den gesamten Zeitrahmen des Bestellungseingangs. Dieser Rahmen kann unter Umständen sehr breit ausfallen, wenn es zu vereinzelt Bestellungen mit überaus langer oder kurzer Vorlaufzeit kommt. Alternativ besteht deshalb die Möglichkeit, die Kennzahlen auf den Zeitrahmen zu fokussieren, in dem ein Großteil der Bestellmenge eingegangen ist. So kann sich der Endpunkt beispielsweise auf die Vorlaufzeit beziehen, zu der durchschnittlich 10% der Bestellmenge vorliegt. Analog kann der Anfangspunkt die Vorlaufzeit markieren, zu der durchschnittlich 90% der Bestellungen bekannt sind. So kann die Spannweite auf den Kern des Bestellungseingangs konzentriert werden. Statt der fixen Werte von 10% und 90% sind natürlich auch andere Schwellenwerte denkbar. Verallgemeinernd können für die Definition also beliebige Quantile der anteilig vorliegenden Bestellmenge eingesetzt werden. Die Quantile für Anfangs- und Endpunkt müssen für eine sinnvolle Analyse allerdings mit ausreichendem Abstand gewählt werden. In den folgenden Ausführungen wird jedoch vorwiegend die vorherige Definition, die den gesamten Zeitrahmen berücksichtigt, zugrunde gelegt.

Mit den Kennzahlen zur Spannweite kann eine Supply Chain das Vorlaufzeitfenster eingrenzen, in dem die Bestellungen eingehen. Der Endpunkt markiert für die Supply Chain die maximale Vorlaufzeit, mit der Bestellungen eingegangen sind. Langfristigere Bestellungen lagen entsprechend für die Planung in der Supply Chain nicht vor. Umgekehrt stellt der Anfangspunkt das Ende des Vorlaufzeitfensters dar. Die genaue Nachfrage für die nächsten e_{start} Zeiträume stand somit bereits jederzeit fest. Die Spannweite als Differenz der beiden Punkte beschreibt die Dauer des Vorlaufzeitfensters. Sie ist damit in Bezug auf die Wunschlieferzeit ein Maß für die Unterschiede im Bestellverhalten.

5.1.2. Durchschnittliche Streuung

Der zweite Kennzahlenbereich soll die Streuung vorlaufzeitübergreifend bewerten. Bei einer kontinuierlichen Betrachtung der Vorlaufzeit ist dies die Durchschnittsstreuung des farblich markierten Bereichs in Abbildung 5.3. Im Fall der diskreten Betrachtung ist




Abbildung 5.3.: Durchschnittsstreuung

die Durchschnittsstreuung für die exemplarisch durch gestrichelte Linien gekennzeichneten Vorlaufzeiten zu berechnen. Die Kennzahlen, die die durchschnittliche Standardabweichung charakterisieren, werden mit $K_{2,\sigma}$ abgekürzt. Für die kumuliert vorliegende Bestellmenge ist die Kennzahl folgendermaßen definiert:

$K_{2,\sigma}(t_1, t_n, D_{Aes})$ Durchschnittsstandardabweichung der kumuliert vorliegenden Bestellmenge für die Aggregationsebene **A** bei Betrachtung der Bestellungen mit Wunschlieferszeitpunkten zwischen t_1 und t_n .

Es gilt

$$K_{2,\sigma}(t_1, t_n, D_{Aes}) = \sqrt{\sum_{e=e_{start}}^{e_{end}} \sigma(t_1, t_n, D_{Aes})^2 / K_{1,Range}(t_1, t_n, A)} \quad (5.1.1)$$

Für die kumuliert vorliegende Bestellmenge ist die Durchschnittsstandardabweichung also über das arithmetische Mittel der Stichprobenvarianzen definiert. Die Varianzen entsprechen den quadrierten Standardabweichungen. Das vorlaufzeitübergreifend berechnete arithmetische Mittel dieser Varianzen ist die Durchschnittsvarianz. Durch das Ziehen der einfachen Quadratwurzel ergibt sich die durchschnittliche Standardabweichung.

Die Durchschnittsstandardabweichungen für die ausstehende und anteilig vorliegende Bestellmenge sind analog definiert. Zu beachten ist, dass die Streuungswerte für den Anfangspunkt nicht berücksichtigt werden, da diese immer 0 sind.² Bei der Bestimmung

²Da keine Bestellungen mit einer kürzeren Vorlaufzeit als e_{start} eingegangen sind, gilt stets $U_{Ae_{starts}} = 0$ und damit $\sigma(t_1, t_n, U_{Ae_{starts}}) = 0$. Entsprechend der Definition des Anfangspunkts gilt immer $X_{Ae_{starts}} = 100\%$ und $\sigma(t_1, t_n, X_{Ae_{starts}}) = 0\%$.

von $K_{2,\sigma}(t_1, t_n, U_{Aes})$ und $K_{2,\sigma}(t_1, t_n, X_{Aes})$ ist die Berechnung des arithmetischen Mittels entsprechend anzupassen.

Tabelle 5.1 stellt die Berechnung für das Beispiel aus den Tabellen 3.3 bis 3.5 in Kapitel 3 dar. Anfangspunkt der Spannweite war hier $K_{1,Start}(t_1, t_n, A) = 1$ und Endpunkt $K_{1,End}(t_1, t_n, A) = 6$. Es gilt also $K_{1,Range}(t_1, t_n, A) = 6$.

	$\sigma(t_1, t_n, D_{Aes})$	$\sigma(t_1, t_n, U_{Aes})$	$\sigma(t_1, t_n, X_{Aes})$
$e = 6$	90,6	147,5	9,8%
$e = 5$	130,6	150,3	13,5%
$e = 4$	136,6	86,4	9,9%
$e = 3$	161,9	85,2	8,4%
$e = 2$	140,2	52,9	4,8%
$e = 1$	142,4	0,0	0,0%
$K_{2,\sigma}$	135,5	111,3	9,7%

Tabelle 5.1.: Berechnung Durchschnittsstreuung

Analog zur Standardabweichung kann der Durchschnittsvariationskoeffizient ermittelt werden. Da dies ein relatives Maß der Streuung ist, wird es einfach als arithmetisches Mittel berechnet. Die Kennzahlen für die Durchschnittsvariationskoeffizienten werden mit $K_{2,VK}$ abgekürzt:

$K_{2,VK}(t_1, t_n, D_{Aes})$ Durchschnittsvariationskoeffizient der kumuliert vorliegenden Bestellmenge für die Aggregationsebene A bei Betrachtung der Bestellungen mit Wunschliefzeitpunkten zwischen t_1 und t_n .

Es gilt

$$K_{2,VK}(t_1, t_n, D_{Aes}) = \sum_{e=e_{start}}^{e_{end}} VK(t_1, t_n, D_{Aes}) / K_{1,Range}(t_1, t_n, A) \quad (5.1.2)$$

Für die ausstehende und anteilig vorliegende Bestellmenge ist der Variationskoeffizient zum Anfangspunkt nicht definiert bzw. 0, weshalb dieser Wert in der Berechnung auch hier nicht verwendet wird.³ Die Kennzahlen für die ausstehende und anteilig vorliegende Bestellmenge $K_{2,VK}(t_1, t_n, U_{Aes})$ und $K_{2,VK}(t_1, t_n, X_{Aes})$ können entsprechend angepasst errechnet werden. Tabelle 5.2 führt die Durchschnittsvariationskoeffizienten für das bekannte Beispiel auf.

Durchschnittsstandardabweichung und -variationskoeffizient geben Aufschluss über die absolute und relative Konstanz des Bestellungseingangs unabhängig von einer bestimmten Vorlaufzeit. Sie erlauben eine allgemeine Einschätzung der Streuung, ohne möglicherweise signifikante Unterschiede für verschiedene Vorlaufzeiten zu berücksichtigen. In obigem Beispiel variiert die Streuung der ausstehenden Bestellmenge zwischen 52,9 und

³Allgemein werden Vorlaufzeitpunkte, für die der Variationskoeffizient nicht definiert ist, weil das entsprechende arithmetische Mittel im Nenner 0 ist, bei der Berechnung des Durchschnittsvariationskoeffizienten nicht berücksichtigt.

	$VK(t_1, t_n, D_{Aes})$	$VK(t_1, t_n, U_{Aes})$	$VK(t_1, t_n, X_{Aes})$
$e = 6$	74,5%	16,9%	81,2%
$e = 5$	47,2%	20,9%	49,0%
$e = 4$	26,1%	18,3%	19,0%
$e = 3$	21,0%	37,6%	10,9%
$e = 2$	15,3%	66,1%	5,2%
$e = 1$	14,3%		0,0%
$K_{2,VK}$	33,1%	31,9%	33,1%

Tabelle 5.2.: Berechnung Durchschnittsvariationskoeffizient

150,3. Dieser Umstand kann nicht aus der Durchschnittsstandardabweichung von 111,3 abgeleitet werden. Kennzahlen, die hierzu vorlaufzeitübergreifende Rückschlüsse erlauben, folgen im nächsten Abschnitt.

Die Kennzahlen dieses Abschnitts ermöglichen der Supply Chain, ex-post die Volatilität im Bestellverhalten zu bewerten. Je höher eine Kennzahl ist, desto größer waren die Unterschiede im Bestellverhalten. Ist das Bestellverhalten für jeden Wunschlieferzeitpunkt identisch, so besteht keine Streuung und die Kennzahlen sind alle 0. Diese Situation tritt in der betrieblichen Realität allerdings nicht auf. Die Kennzahlen beziehen sich dabei auf die unterschiedlichen Bestellmengenarten – kumuliert vorliegende, ausstehende oder anteilig vorliegende Menge – und erlauben so der Supply Chain eine differenzierte Bewertung und einen Vergleich der Volatilität der verschiedenen Bestellmengen. Eine hohe Streuung bei der kumuliert vorliegenden Bestellmenge impliziert beispielsweise nicht notwendigerweise das gleiche für die anteilig vorliegende Bestellmenge.⁴ Die Analyse des Bestellverhaltens ist für eine Supply Chain wichtig, wenn sie die ADI für zukünftige Planungsaufgaben verwendet. Volatilität im Bestellverhalten muss von der Supply Chain in den Plänen berücksichtigt werden, um auf Unterschiede im Bestellverhalten auch in der entsprechenden Höhe vorbereitet zu sein.

5.1.3. Form der Streuung

Die im vergangenen Abschnitt beschriebenen Kennzahlen ermöglichen eine vorlaufzeitübergreifende ex-post Einschätzung der absoluten und relativen Streuung im Bestellsingang. Unterschiede zwischen den Vorlaufzeiten werden dabei nicht berücksichtigt. Wie in Abbildung 5.4 illustriert, können solche allerdings auftreten.

Der linke Graph stellt beispielhaft die durchschnittlich kumuliert vorliegende Bestellmenge sowie die dazugehörige Standardabweichung für die Vorlaufzeiten e bis $e+5$ dar. Nach der Subtraktion der Durchschnittswerte verbleiben im rechten Graph die Standardabwei-

⁴Selbst wenn die anteilig vorliegende Bestellmenge für eine Vorlaufzeit immer identisch ist, kann die kumuliert vorliegende Bestellmenge hier immer noch variieren. So kann die anteilig vorliegende Bestellmenge für eine bestimmte Vorlaufzeit immer 50% betragen. Wenn zu einem Wunschlieferzeitpunkt 100 und zum anderen 200 Stück nachgefragt werden, so ist die kumuliert vorliegende Bestellmenge für die gleiche Vorlaufzeit einmal 50 und einmal 100 Stück.




Abbildung 5.4.: Beispiel zum Zusammenhang von Streuung und Vorlaufzeit

chungen für die unterschiedlichen Vorlaufzeiten. Die Kennzahlen dieses Abschnitts sollen die Bewertung dieser Unterschiede gewährleisten.

Datengrundlage für die Kennzahlen sind die Standardabweichungen und Variationskoeffizienten für die Vorlaufzeiten zwischen Anfangs- und Endpunkt, wie in Tabelle 5.3 aufgeführt. Dabei werden nur bei der kumuliert vorliegenden Bestellmenge die Standardabweichungen bzw. der Variationskoeffizient zum Anfangspunkt miteinbezogen. Im Fall der ausstehenden und anteilig vorliegenden Bestellmenge werden diese Werte wie im vorherigen Abschnitt nicht berücksichtigt, da sie stets 0 oder nicht definiert sind.

	Art der Bestellmenge	Datengrundlage
Standardabweichungen	Kumuliert	$\sigma(t_1, t_n, D_{\mathbf{A}e_{start}s}), \dots, \sigma(t_1, t_n, D_{\mathbf{A}e_{end}s})$
	Ausstehend	$\sigma(t_1, t_n, U_{\mathbf{A}(e_{start}+1)s}), \dots, \sigma(t_1, t_n, U_{\mathbf{A}e_{end}s})$
	Anteilig	$\sigma(t_1, t_n, X_{\mathbf{A}(e_{start}+1)s}), \dots, \sigma(t_1, t_n, X_{\mathbf{A}e_{end}s})$
Variationskoeffizienten	Kumuliert	$VK(t_1, t_n, D_{\mathbf{A}e_{start}s}), \dots, VK(t_1, t_n, D_{\mathbf{A}e_{end}s})$
	Ausstehend	$VK(t_1, t_n, U_{\mathbf{A}(e_{start}+1)s}), \dots, VK(t_1, t_n, U_{\mathbf{A}e_{end}s})$
	Anteilig	$VK(t_1, t_n, X_{\mathbf{A}(e_{start}+1)s}), \dots, VK(t_1, t_n, X_{\mathbf{A}e_{end}s})$

Tabelle 5.3.: Datengrundlage der Formbewertung

Die aufgeführten Standardabweichungen und Variationskoeffizienten bilden Zeitreihen, die mit den Mitteln der Zeitreihenanalyse untersuchbar sind. An dieser Stelle soll die Analyse auf die Identifikation eines einfachen linearen Trends in diesen Zeitreihen begrenzt sein. Die Kennzahlen zur Form der Streuung geben diesen Trend wieder. Der Einsatz anderer Modelle aus der Zeitreihenanalyse ist auch möglich. So können beispielsweise Mo-




Abbildung 5.5.: Beispiele für unterschiedliche Trends

delle verwendet werden, die Saisonalitäten berücksichtigen. Es wird hier allerdings darauf verzichtet, den Einsatz dieser Modelle detailliert zu beschreiben, weswegen die Aussagen auf die Analyse eines linearen Trends begrenzt sind. Es ist dem Anwender freigestellt, andere Modelle situationsbedingt zusätzlich einzusetzen, um das Bestellverhalten genauer zu charakterisieren.

In Abbildung 5.5 sind unterschiedliche Situationen mit verschiedenen Trends bei den Streuungswerten abgebildet. Die Punkte stehen dabei für die tatsächliche ex-post ermittelte Streuung zu unterschiedlichen Vorlaufzeiten. Die Trends, dargestellt durch die durchgezogenen Linien, beziehen sich entsprechend auf die Entwicklung der Streuung bei veränderter Vorlaufzeit. Ein positiver Trend impliziert eine steigende Streuung mit zunehmender Vorlaufzeit, wie im linken Graphen illustriert. Der mittlere Graph stellt die Situation ohne Trend dar. In diesem Fall ist die Streuung unabhängig von der Vorlaufzeit und abgesehen von zufälligen Schwankungen konstant. Im Fall eines negativen Trends sinkt die Streuung mit zunehmender Vorlaufzeit. Diese Situation ist im rechten Graphen abgebildet.

Für die Standardabweichung der vorliegenden Bestellmenge $\sigma(t_1, t_n, D_{\text{Aes}})$ kann der lineare Trend durch eine Gleichung folgender Form dargestellt werden:

$$\sigma(t_1, t_n, D_{\text{Aes}}) = \beta_0(\sigma(t_1, t_n, D_{\text{Aes}})) + \beta_1(\sigma(t_1, t_n, D_{\text{Aes}})) \cdot e + \varepsilon(\sigma(t_1, t_n, D_{\text{Aes}})) \quad (5.1.3)$$

Die Gleichung setzt sich aus drei Komponenten zusammen:

- $\beta_0(\sigma(t_1, t_n, D_{\text{Aes}}))$: y-Achsenabschnitt bzw. konstanter Teil der Trendgeraden
- $\beta_1(\sigma(t_1, t_n, D_{\text{Aes}}))$: Steigung der Trendgeraden
- $\varepsilon(\sigma(t_1, t_n, D_{\text{Aes}}))$: Verbleibende zufällige Abweichung von der Trendgeraden⁵

⁵Es ist hervorzuheben, dass sich $\varepsilon(\sigma(t_1, t_n, D_{\text{Aes}}))$ auf einen Streuungswert $\sigma(t_1, t_n, D_{\text{Aes}})$ und nicht eine Vorlaufzeit e bezieht.

Analoge Gleichungen können für die ausstehende und anteilig vorliegende Bestellmenge aufgestellt werden. Hierfür ist $\sigma(t_1, t_n, D_{\text{Aes}})$ durch $\sigma(t_1, t_n, U_{\text{Aes}})$ bzw. $\sigma(t_1, t_n, X_{\text{Aes}})$ zu ersetzen. Die Gleichung für die Variationskoeffizienten ergibt sich, wenn σ durch VK ausgetauscht wird.

Relevant für die Analyse der Form der Streuung ist primär die Steigung der Trendgeraden $\beta_1(\sigma(t_1, t_n, D_{\text{Aes}}))$. In dem in Abbildung 5.5 illustrierten Fall eines positiven Trends gilt $\beta_1(\sigma(t_1, t_n, D_{\text{Aes}})) > 0$. Es ist in Abbildung 5.5 darauf zu achten, dass die jeweils rechte vertikale Achse den Wunschlieferzeitpunkt markiert und die Vorlaufzeit steigt, je weiter links sie betrachtet wird. Für den negativen Trend ist $\beta_1(\sigma(t_1, t_n, D_{\text{Aes}})) < 0$ und ohne Trend $\beta_1(\sigma(t_1, t_n, D_{\text{Aes}})) = 0$. Je größer $\beta_1(\sigma(t_1, t_n, D_{\text{Aes}}))$ ist, desto stärker ist die Steigung der Trendgeraden und sind damit die Unterschiede in der Streuung für unterschiedliche Vorlaufzeiten.

Die in Kapitel 4 vorgestellten Berechnungsverfahren für eine Trendgerade können hier eingesetzt werden. Für die kumuliert vorliegenden Bestellmengen ergeben sich folgende Formeln:

$$\beta_0(\sigma(t_1, t_n, D_{\text{Aes}})) =$$

$$\frac{\sum_{e=e_{\text{start}}}^{e_{\text{end}}} e^2 \sum_{e=e_{\text{start}}}^{e_{\text{end}}} \sigma(t_1, t_n, D_{\text{Aes}}) - \sum_{e=e_{\text{start}}}^{e_{\text{end}}} e \sum_{e=e_{\text{start}}}^{e_{\text{end}}} e \cdot \sigma(t_1, t_n, D_{\text{Aes}})}{K_{1,\text{Range}}(t_1, t_n, \mathbf{A}) \cdot \sum_{e=e_{\text{start}}}^{e_{\text{end}}} e^2 - \left(\sum_{e=e_{\text{start}}}^{e_{\text{end}}} e \right)^2} \quad (5.1.4)$$

$$\beta_1(\sigma(t_1, t_n, D_{\text{Aes}})) =$$

$$\frac{K_{1,\text{Range}}(t_1, t_n, \mathbf{A}) \cdot \sum_{e=e_{\text{start}}}^{e_{\text{end}}} e \cdot \sigma(t_1, t_n, D_{\text{Aes}}) - \sum_{e=e_{\text{start}}}^{e_{\text{end}}} e \sum_{e=e_{\text{start}}}^{e_{\text{end}}} \sigma(t_1, t_n, D_{\text{Aes}})}{K_{1,\text{Range}}(t_1, t_n, \mathbf{A}) \cdot \sum_{e=e_{\text{start}}}^{e_{\text{end}}} e^2 - \left(\sum_{e=e_{\text{start}}}^{e_{\text{end}}} e \right)^2} \quad (5.1.5)$$

Durch das Ersetzen von $\sigma(t_1, t_n, D_{\text{Aes}})$ durch $\sigma(t_1, t_n, U_{\text{Aes}})$ bzw. $\sigma(t_1, t_n, X_{\text{Aes}})$ wird die Trendgerade für die ausstehende bzw. anteilig vorliegende Bestellmenge kalkuliert. Es ist zu beachten, dass dann die Werte für den Anfangszeitpunkt nicht berücksichtigt werden. Entsprechend beginnen die Summen erst mit $e = e_{\text{start}} + 1$, und für $K_{1,\text{Range}}(t_1, t_n, \mathbf{A})$ ist $K_{1,\text{Range}}(t_1, t_n, \mathbf{A}) - 1$ einzusetzen. Zur Berechnung der Trendgeraden für die Variationskoeffizienten ist σ gegen VK auszutauschen.

Entscheidend für die Bewertung der Unterschiede zwischen den Streuungswerten ist die Steigung der Trendgeraden. Die Kennzahlen werden für die Standardabweichungen durch $K_{3,\sigma,\text{Trend}}$ und für die Variationskoeffizienten durch $K_{3,VK,\text{Trend}}$ abgekürzt. Die sechs Kennzahlen sind Tabelle 5.4 zu entnehmen.

Für das Beispiel aus dem vorherigen Abschnitt ergeben sich die in Tabelle 5.5 aufgeführten Kennzahlenwerte. Die Kennzahlen zur Form der Streuung erlauben eine ex-post Einschätzung der Unterschiede bei Standardabweichungen und Variationskoeffizienten zu verschiedenen Vorlaufzeiten. Ein positiver Wert impliziert steigende Werte für länge-

	Datengrundlage	Kennzahl
Standard- abweichungen	$\sigma(t_1, t_n, D_{\mathbf{A}e_{start}s}), \dots, \sigma(t_1, t_n, D_{\mathbf{A}e_{end}s})$	$K_{3,\sigma,Trend}(t_1, t_n, D_{\mathbf{A}es})$ $= \beta_1(\sigma(t_1, t_n, D_{\mathbf{A}es}))$
	$\sigma(t_1, t_n, U_{\mathbf{A}(e_{start}+1)s}), \dots, \sigma(t_1, t_n, U_{\mathbf{A}e_{end}s})$	$K_{3,\sigma,Trend}(t_1, t_n, U_{\mathbf{A}es})$ $= \beta_1(\sigma(t_1, t_n, U_{\mathbf{A}es}))$
	$\sigma(t_1, t_n, X_{\mathbf{A}(e_{start}+1)s}), \dots, \sigma(t_1, t_n, X_{\mathbf{A}e_{end}s})$	$K_{3,\sigma,Trend}(t_1, t_n, X_{\mathbf{A}es})$ $= \beta_1(\sigma(t_1, t_n, X_{\mathbf{A}es}))$
Variations- koeffizienten	$VK(t_1, t_n, D_{\mathbf{A}e_{start}s}), \dots, VK(t_1, t_n, D_{\mathbf{A}e_{end}s})$	$K_{3,VK,Trend}(t_1, t_n, D_{\mathbf{A}es})$ $= \beta_1(VK(t_1, t_n, D_{\mathbf{A}es}))$
	$VK(t_1, t_n, U_{\mathbf{A}(e_{start}+1)s}), \dots, VK(t_1, t_n, U_{\mathbf{A}e_{end}s})$	$K_{3,VK,Trend}(t_1, t_n, U_{\mathbf{A}es})$ $= \beta_1(VK(t_1, t_n, U_{\mathbf{A}es}))$
	$VK(t_1, t_n, X_{\mathbf{A}(e_{start}+1)s}), \dots, VK(t_1, t_n, X_{\mathbf{A}e_{end}s})$	$K_{3,VK,Trend}(t_1, t_n, X_{\mathbf{A}es})$ $= \beta_1(VK(t_1, t_n, X_{\mathbf{A}es}))$

Tabelle 5.4.: Kennzahlen zur Bewertung der Form der Streuung

re Vorlaufzeiten. Bei einem negativen Wert ist mit dem umgekehrten Effekt sinkender Werte bei zunehmender Vorlaufzeit zu rechnen. Die Unterschiede zwischen den Werten wachsen dabei mit der Steigung der Geraden an. Bei einer Kennzahl von 0 wären keine Unterschiede bei Standardabweichungen und Variationskoeffizienten im Zusammenhang mit der Vorlaufzeit abzuleiten.

Die beschriebenen Kennzahlen beziehen sich immer auf die ex-post beobachtete Stichprobe. Um zu überprüfen, ob die errechnete Trendsteigung signifikant von 0 abweicht, kann der in Abschnitt 4.1.2 vorgestellte Student-t-Test eingesetzt werden. Weicht die Trendsteigung nicht ab, kann die Schlussfolgerung sein, dass kein Trend vorliegt. Die entsprechende Kennzahl kann dann manuell auf 0 gesetzt werden.

Der Test beginnt mit der Festsetzung des Signifikanzniveaus α und der Berechnung der Testgröße T . Für die kumuliert vorliegende Bestellmenge ist $T = \frac{\beta_1(\sigma(t_1, t_n, D_{\mathbf{A}es}))}{s_{\beta_1(\sigma(t_1, t_n, D_{\mathbf{A}es}))}}$, wobei $s_{\beta_1(\sigma(t_1, t_n, D_{\mathbf{A}es}))}$ die Standardabweichung der Trendgeraden ist.

$$\text{Es gilt } s_{\beta_1(\sigma(t_1, t_n, D_{\mathbf{A}es}))} = \sqrt{\frac{\sum_{e=e_{start}}^{e_{end}} (\varepsilon(\sigma(t_1, t_n, D_{\mathbf{A}es})))^2}{(K_{1,Range}(t_1, t_n, \mathbf{A}) - 2) \sum_{e=e_{start}}^{e_{end}} \left(\frac{e_{start} + e_{end}}{2} - e\right)^2}}}.^6$$

Nach Bestimmung des Wertes $t = t_{1-\alpha/2; K_{1,Range}(t_1, t_n, \mathbf{A}) - 2}$, den eine Student-t-Verteilung mit $(K_{1,Range}(t_1, t_n, \mathbf{A}) - 2)$ -Freiheitsgraden mit einer Wahrscheinlichkeit von $1 - \alpha/2$ nicht überschreitet, kann der Test zu folgenden Schlussfolgerungen kommen:

- Wenn $-t \leq T \leq t$, ist nicht auszuschließen, dass die Steigung der Trendgeraden 0 ist. In diesem Fall kann $K_{3,\sigma,Trend}(t_1, t_n, D_{\mathbf{A}es})$ manuell auf 0 gesetzt werden.
- Andernfalls gilt $|T| > t$ und $\beta_1(\sigma(t_1, t_n, D_{\mathbf{A}es}))$ weicht signifikant von 0 ab. Die Hypothese, dass die Trendsteigung 0 sein kann, ist zu verwerfen und entsprechend

⁶Die Anpassungen bei Verwendung für die ausstehende bzw. anteilig vorliegende Bestellmenge sowie den Variationskoeffizienten sind die gleichen wie bereits zuvor bei der Berechnung der Trendsteigung.

	$\sigma(t_1, t_n, D_{Aes})$	$\sigma(t_1, t_n, U_{Aes})$	$\sigma(t_1, t_n, X_{Aes})$
$e = 6$	90,6	147,5	9,8%
$e = 5$	130,6	150,3	13,5%
$e = 4$	136,6	86,4	9,9%
$e = 3$	161,9	85,2	8,4%
$e = 2$	140,2	52,9	4,8%
$e = 1$	142,4	0,0	0,0%
$K_{3,\sigma,Trend}$	-8,9	25,4	1,5%
	$VK(t_1, t_n, D_{Aes})$	$VK(t_1, t_n, U_{Aes})$	$VK(t_1, t_n, X_{Aes})$
$e = 6$	74,5%	16,9%	81,2%
$e = 5$	47,2%	20,9%	49,0%
$e = 4$	26,1%	18,3%	19,0%
$e = 3$	21,0%	37,6%	10,9%
$e = 2$	15,3%	66,1%	5,2%
$e = 1$	14,3%		0,0%
$K_{3,VK,Trend}$	11,5%	-11,5%	19,0%

Tabelle 5.5.: Berechnung Kennzahlen zur Form der Streuung

bleibt $K_{3,\sigma,Trend}(t_1, t_n, D_{Aes})$ unverändert.

Der Test wird exemplarisch für die Standardabweichung bei der kumuliert vorliegenden und ausstehenden Bestellmenge aus dem bekannten Beispiel durchgeführt. Als Signifikanzniveau wird in beiden Fällen $\alpha = 10\%$ gewählt. Die Trendgleichungen haben folgende Form:

- Kumulierte Bestellmenge: $\sigma(t_1, t_n, D_{Aes}) = 165 - 8,9 \cdot e + \varepsilon(\sigma(t_1, t_n, D_{Aes}))$
- Ausstehende Bestellmenge: $\sigma(t_1, t_n, U_{Aes}) = 2,8 + 25,4 \cdot e + \varepsilon(\sigma(t_1, t_n, U_{Aes}))$

Tabelle 5.6 sind die zufälligen Abweichungen zur Berechnung der Standardabweichung zu entnehmen. Für die kumuliert vorliegende Bestellmenge gilt dann $T = -2,0$. Aus der dazugehörigen Student-t-Verteilung mit 4 Freiheitsgraden kann $t = t_{0,95;4} = 2,132$ abgeleitet werden. Es gilt also $-t \leq T \leq t$, womit die Hypothese, dass keine Trendsteigung vorliegt, nicht verworfen werden kann. Die Kennzahl $K_{3,\sigma,Trend}(t_1, t_n, D_{Aes})$ kann nun manuell auf 0 gesetzt werden.

Für die ausstehende Bestellmenge gilt $T = 4,8$. Es ist die Student-t-Verteilung mit 3 Freiheitsgraden zu betrachten, da die Streuung zum Anfangspunkt nicht berücksichtigt wurde. Es gilt $t = t_{0,95;3} = 2,35$. Da $T > t$, kann die Hypothese, es liege kein Trend vor, verworfen werden. Deshalb ist die Kennzahl $K_{3,\sigma,Trend}(t_1, t_n, U_{Aes})$ nicht anzupassen.

Wie im letzten Abschnitt beschrieben, ist die Analyse der Volatilität im Bestellverhalten beim Einsatz der ADI für Planungsaufgaben wichtig. Während die Kennzahlen des letzten Abschnitts eine vorlaufzeitübergreifende durchschnittliche ex-post Einschätzung dieser Konstanz ermöglichen, können Unterschiede in der absoluten und relativen Streuung

	$\varepsilon(\sigma(t_1, t_n, D_{\text{Aes}}))$	$\varepsilon(\sigma(t_1, t_n, U_{\text{Aes}}))$
$e = 6$	20,8	7,8
$e = 5$	-10,3	-20,4
$e = 4$	-7,4	18,1
$e = 3$	-23,7	-6,2
$e = 2$	6,9	0,7
$e = 1$	13,7	
$\sum_{e=e_{\text{start}}(+1)}^{e_{\text{end}}} (\varepsilon(\dots))^2$	1386,5	844,3
$s_{\beta_1(\dots)}$	4,45	5,3
T	-2,0	4,8

Tabelle 5.6.: Beispiel Student-t-Test: Zufällige Abweichungen

durch die Kennzahlen dieses Abschnitts gemessen werden. Durch die ex-post Identifikation möglicherweise signifikanter Differenzen in der Streuung bei verschiedenen Vorlaufzeiten kann die Supply Chain bewerten, wann der ADI-Einsatz besser geeignet war und entsprechend eventuell noch in der Zukunft ist.

5.1.4. Korrelation

Die Regressionsanalyse dient der Ermittlung eines möglichen Zusammenhangs zwischen unabhängigen und abhängigen Werten. Bei der Analyse des Bestellverhaltens ist besonders die Stärke der Korrelation zwischen der kumuliert vorliegenden Bestellmenge und der tatsächlich beobachteten Nachfrage von Interesse. Vor allem für die später untersuchte ADI-Nutzung zur Nachfrageprognose kann dieser Wert ein Indikator für die zu erwartende Zuverlässigkeit der Vorhersagen sein.

In Kapitel 4 wurde der Korrelationskoeffizient R als mögliches Maß zur Einschätzung der Korrelationsstärke vorgestellt. Sei $R(t_1, t_n, D_{\text{Aes}}, D_{\text{A0s}})$ der Korrelationskoeffizient zwischen der zur Vorlaufzeit e kumuliert vorliegenden Bestellmenge und der tatsächlichen Nachfrage. Der Wert ist auf ein beliebiges aber fixes Aggregationslevel \mathbf{A} und die Stichprobe, die zwischen den Zeitpunkten t_1 und t_n erfasst wurde, bezogen. Es gilt entsprechend der bereits vorgestellten Formel:

$$R(t_1, t_n, D_{\text{Aes}}, D_{\text{A0s}}) = \frac{CoV(t_1, t_n, D_{\text{Aes}}, D_{\text{A0s}})}{\sigma(t_1, t_n, D_{\text{Aes}}) \cdot \sigma(t_1, t_n, D_{\text{A0s}})} \quad (5.1.6)$$

Dabei ist die Kovarianz $CoV(t_1, t_n, D_{\text{Aes}}, D_{\text{A0s}})$ zwischen der Bestellmenge zur Vorlaufzeit e und der späteren Nachfrage folgendermaßen definiert:

$CoV(t_1, t_n, D_{\text{Aes}}, D_{\text{A0s}})$ Kovarianz der bis zur Vorlaufzeit e kumuliert vorliegenden Bestellmenge und der Gesamtnachfrage auf der Aggregationsebene \mathbf{A} , basierend auf einer Stichprobe von Wunschlieferszeitpunkten

D_{Aes}	<i>Wunschlieferzeitpunkt</i>						$CoV(\dots)$	$R(\dots)$
	t_1	t_2	t_3	t_4	t_5	t_6		
$e = 6$	100	50	180	0	250	150	3366,7	0,26
$e = 5$	300	150	360	100	450	300	7366,7	0,40
$e = 4$	700	450	540	300	600	550	15733,3	0,81
$e = 3$	1050	650	720	600	750	850	19600,0	0,85
$e = 2$	1150	850	900	750	850	1000	18566,7	0,93
$e = 1$	1200	950	1080	800	900	1050	20266,7	1
$e = 0$	1200	950	1080	800	900	1050		

Tabelle 5.7.: Beispiel Korrelationskoeffizient

zwischen t_1 und t_n .

Es gilt für die korrigierte Stichprobenkovarianz

$$CoV(t_1, t_n, D_{Aes}, D_{A0s}) = \sum_{s=t_1}^{t_n} \frac{(D_{Aes} - \mu(t_1, t_n, D_{Aes})) \cdot (D_{A0s} - \mu(t_1, t_n, D_{A0s}))}{n - 1} \quad (5.1.7)$$

Für das bekannte Beispiel aus Kapitel 3 sind die Werte in Tabelle 5.7 exemplarisch berechnet worden. Die beobachtete Stärke der Korrelation nimmt in diesem Beispiel mit abnehmender Vorlaufzeit zu. Bei einer Vorlaufzeit von $e = 1$ liegt eine perfekte Korrelation mit $R(t_1, t_n, D_{Aes}, D_{A0s}) = 1$ vor, weil zu dieser Vorlaufzeit immer die gesamte Nachfrage bekannt war.

Ziel des Kennzahlensystems ist eine vorlaufzeitübergreifende Bewertung des Bestellverhaltens. Entsprechend sollen die Kennzahlen auch eine vorlaufzeitübergreifende Einschätzung zur Korrelationsstärke ermöglichen. Dabei soll eine Kennzahl die durchschnittliche Korrelationsstärke und eine weitere die Form der Korrelationskoeffizienten bewerten, genauso wie zuvor eine Kennzahl die durchschnittliche Streuung und eine weitere deren Form widerspiegelt hat. Die Kennzahl für den Durchschnitt sei $K_{4,Avg}$ und für die Form $K_{4,Trend}$. Zur Berechnung der durchschnittlichen Korrelationsstärke diskutieren Silver und Dunlap (1987) zwei Vorgehensweisen:

1. Einfache Berechnung des arithmetischen Mittels über die Korrelationskoeffizienten
2. Berechnung des arithmetischen Mittels nach Fisher-z-Transformation

Das Vorgehen im ersten Fall ist einfach. Turnage und Muchinsky (1984) setzen es beispielsweise in ihren Analysen ein, um den Einfluss von Assessment Center-Bewertungen auf die spätere Arbeitsleistung zu untersuchen. Es muss das arithmetische Mittel über alle Korrelationskoeffizienten für Vorlaufzeiten zwischen dem Endpunkt und dem Zeitpunkt $e_{start} + 1$ direkt vor dem Anfangspunkt gebildet werden. Der Anfangspunkt wird nicht miteinbezogen, da zu diesem Zeitpunkt stets die gesamte Nachfrage vorliegt und damit der Korrelationskoeffizient immer 1 ist. Es gilt also:

$$K_{4,Avg}(t_1, t_n, D_{Aes}) = \sum_{e=e_{start}+1}^{e_{end}} R(t_1, t_n, D_{Aes}, D_{A0s}) / (K_{1,Range}(t_1, t_n, A) - 1) \quad (5.1.8)$$

Das zweite Vorgehen wird u.a. von Rambo u.a. (1983) in ihren Untersuchungen verwendet. Sie analysieren den Zusammenhang zwischen ausgewählten Aspekten der Arbeitsbedingungen und der Arbeitsleistung. Bei diesem Vorgehen muss zunächst eine Fisher-z-Transformation⁷ der Korrelationskoeffizienten durchgeführt werden. Dabei wird $R \in (-1, 1)$ in

$$z = \frac{1}{2} \ln(1 + R) / (1 - R) \quad (5.1.9)$$

transformiert. Anschließend wird das arithmetische Mittel \bar{z} über die transformierten Werte gebildet. Durch Retransformation des resultierenden Wertes ergibt sich

$$K_{4,Avg}(t_1, t_n, D_{Aes}) = (e^{2\bar{z}} - 1) / (e^{2\bar{z}} + 1) \quad (5.1.10)$$

Beide Verfahren unterliegen einem systematischen statistischen Fehler aufgrund der Schiefe des Korrelationskoeffizienten. Silver und Dunlap (1987) haben umfangreiche Simulationen mit künstlich erzeugten Datensätzen durchgeführt. Das Verfahren, das die Fisher-z-Transformation verwendet, hat dabei den durchschnittlichen Korrelationskoeffizienten genauer abgeschätzt. Insbesondere bei kleineren Datensätzen waren die Ergebnisse näher am Korrelationskoeffizienten, der den zufällig erzeugten Werten zugrunde lag. Beide Verfahren können aber zur Berechnung der Kennzahl eingesetzt werden. Es werden für die beiden Verfahren allerdings nicht zwei separate Kennzahlen definiert, da es sich nur um unterschiedliche statistische Verfahren zur Berechnung der durchschnittlichen Korrelation handelt. Würden zwei getrennte Kennzahlen definiert, so wäre deren Bedeutung die gleiche. Es soll hier vermieden werden, dass das Kennzahlensystem zu umfangreich und eine kompakte Charakterisierung des Bestellverhaltens verhindert wird. Der Anwender kann das für ihn geeignetere Verfahren eigenständig bestimmen. In Tabelle 5.8 ist die Kennzahl mit beiden Vorgehensweisen für das Beispiel aus Tabelle 5.7 berechnet worden. Sei $R_z(t_1, t_n, D_{Aes}, D_{A0s})$ die Fisher-z-Transformation von $R(t_1, t_n, D_{Aes}, D_{A0s})$. Das erste Verfahren resultiert in $K_{4,Avg}(t_1, t_n, D_{Aes}) = 0,65$, das zweite in $K_{4,Avg}(t_1, t_n, D_{Aes}) = 0,74$.

Die Kennzahl zur Form der Korrelationskoeffizienten ist analog zur Kennzahl für die Form der Streuung auf die Identifikation eines Trends fokussiert. Der Trend kann sowohl auf Basis der Korrelationskoeffizienten als auch der Werte nach der Fisher-z-Transformation berechnet werden. Die Entscheidung für das geeignete Verfahren liegt wie bei der vorherigen Kennzahl beim Anwender. Die Kennzahl soll die Steigung der Trendgeraden wiedergeben und so gleichzeitig die Stärke eines möglichen Trends beschreiben. Die Gleichung

⁷Zur Fisher-z-Transformation siehe Fisher (1921)

	Vorlaufzeit					Arithm. Mittel	Retransfor- mierter Wert
	$e = 6$	$e = 5$	$e = 4$	$e = 3$	$e = 2$		
$R(\dots)$	0,26	0,40	0,81	0,85	0,93	0,65	
$R_z(\dots)$	0,27	0,42	1,12	1,26	1,66	0,95	0,74

Tabelle 5.8.: Beispiel Kennzahlberechnung für durchschnittlichen Korrelationskoeffizienten

zur Berechnung der Trendsteigung wurde bereits erläutert. In diesem Anwendungsbeispiel lautet sie

- für die Korrelationskoeffizienten:

$$K_{4,Trend}(t_1, t_n, D_{Aes}) = \beta_1(R(t_1, t_n, D_{Aes}, D_{A0s})) =$$

$$\frac{(K_{1,Range}(\dots) - 1) \cdot \sum_{e=e_{start}+1}^{e_{end}} e \cdot R(\dots) - \sum_{e=e_{start}+1}^{e_{end}} e \sum_{e=e_{start}+1}^{e_{end}} R(\dots)}{K_{1,Range}(\dots) \cdot \sum_{e=e_{start}+1}^{e_{end}} e^2 - \left(\sum_{e=e_{start}+1}^{e_{end}} e \right)^2} \quad (5.1.11)$$

- und für die Fisher-z-transformierten Werte:

$$K_{4,Trend}(t_1, t_n, D_{Aes}) = \beta_1(R_Z(t_1, t_n, D_{Aes}, D_{A0s})) =$$

$$\frac{(K_{1,Range}(\dots) - 1) \cdot \sum_{e=e_{start}+1}^{e_{end}} e \cdot R_Z(\dots) - \sum_{e=e_{start}+1}^{e_{end}} e \sum_{e=e_{start}+1}^{e_{end}} R_Z(\dots)}{K_{1,Range}(\dots) \cdot \sum_{e=e_{start}+1}^{e_{end}} e^2 - \left(\sum_{e=e_{start}+1}^{e_{end}} e \right)^2} \quad (5.1.12)$$

Im Fall von $K_{4,Trend}(t_1, t_n, D_{Aes}) > 0$ liegt eine positive Trendsteigung vor, und die Korrelationsstärke würde mit zunehmender Vorlaufzeit wachsen. Umgekehrt würde die Stärke bei einem negativen Trend abnehmen. Für obiges Beispiel wurden die Werte in Tabelle 5.9 berechnet. Die Kennzahlen deuten auf einen negativen Trend hin. Die Korrelationskoeffizienten, die mit zunehmender Vorlaufzeit kontinuierlich fallen, passen zu diesem Ergebnis.

	Vorlaufzeit					$K_{4,Trend}(\dots)$
	$e = 6$	$e = 5$	$e = 4$	$e = 3$	$e = 2$	
$R(t_1, t_n, D_{Aes}, D_{A0s})$	0,26	0,40	0,81	0,85	0,93	-0,18
$R_Z(t_1, t_n, D_{Aes}, D_{A0s})$	0,27	0,42	1,12	1,26	1,66	-0,36

Tabelle 5.9.: Beispiel Kennzahlberechnung für Trend bei Korrelationskoeffizienten

Wie in Abschnitt 5.1.3 kann mit dem Student-t-Test überprüft werden, ob die berechnete Trendsteigung signifikant von 0 abweicht. Ist das nicht der Fall, kann die Schlussfolgerung sein, dass kein Trend vorliegt. Die Kennzahl kann dann manuell auf 0 gesetzt werden. Die Testgröße für den Student-t-Test bei der Trendsteigung der Korrelationskoeffizienten ist $T = \beta_1(R(t_1, t_n, D_{Aes}, D_{A0s})) / s_{\beta_1(R(t_1, t_n, D_{Aes}, D_{A0s}))}$.

- $s_{\beta_1(R(t_1, t_n, D_{Aes}, D_{A0s}))} = \sqrt{\frac{\sum_{e=e_{start}+1}^{e_{end}} (\varepsilon(R(t_1, t_n, D_{Aes}, D_{A0s})))^2}{(K_{1,Range}(t_1, t_n, \mathbf{A})-3) \sum_{e=e_{start}+1}^{e_{end}} \left(\frac{e_{start}+e_{end}}{2} - e\right)^2}}$ ist die Standardabweichung der Trendgeraden.
- $\varepsilon(R(t_1, t_n, D_{Aes}, D_{A0s}))$ ist die Abweichung des Korrelationskoeffizienten zur Vorlaufzeit e von der ermittelten Trendgeraden.

Nach Bestimmung des Signifikanzniveaus α und Ermittlung des Wertes, den eine Student-t-Verteilung mit $K_{1,Range}(t_1, t_n, \mathbf{A})-3$ -Freiheitsgraden⁸ mit einer Wahrscheinlichkeit von $1 - \alpha/2$ nicht überschreitet, kann der Test zu folgenden Ergebnissen kommen:

- Wenn $-t \leq T \leq t$, weicht die Trendsteigung nicht signifikant von 0 ab. Es liegt also möglicherweise kein Trend vor. Die Kennzahl kann deshalb manuell auf 0 gesetzt werden.
- Sonst gilt $|T| > t$, womit die Hypothese, dass die Trendsteigung 0 sein kann, zu verwerfen ist.

Für das Beispiel aus Tabelle 5.9 ergeben sich die in Tabelle 5.10 aufgeführten Werte. Bei einem Signifikanzniveau $\alpha = 10\%$ ergibt sich für eine Student-t-Verteilung mit drei Freiheitsgraden $t_{0,95;3} = 2,35$. Da in beiden Fällen $|T| > t$ gilt, ist die Annahme eines negativen Trends auf Basis des Student-t-Tests hier nicht zu widerlegen.

	Vorlaufzeit					$s_{\beta_1(R(\dots))}$	$\beta_1(R(\dots))$	T
	$e = 6$	$e = 5$	$e = 4$	$e = 3$	$e = 2$			
$\varepsilon(R(\dots))$	0,26	0,40	0,81	0,85	0,93	0,036	-0,18	-5,01
$\varepsilon(R_Z(\dots))$	0,27	0,42	1,12	1,26	1,66	0,046	-0,36	-7,87

Tabelle 5.10.: Student-t-Test für Formkennzahl

⁸Es sind $K_{1,Range}(t_1, t_n, \mathbf{A})-3$ -Freiheitsgrade, weil der Korrelationskoeffizient zum Anfangspunkt, der immer 1 ist, nicht berücksichtigt wird. Aus diesem Grund wird auch $K_{1,Range}(t_1, t_n, \mathbf{A})-3$ im Nenner von $s_{\beta_1(R(t_1, t_n, D_{Aes}, D_{A0s}))}$ benutzt.

Die Kennzahlen zur Korrelation bewerten ex-post die Stärke der Korrelation zwischen der ADI und der tatsächlichen Nachfrage. Dabei wird der Korrelationskoeffizient als Maß für die Korrelationsstärke verwendet. Analog zu den Kennzahlen für die Streuung in den Abschnitten 5.1.2 und 5.1.3 wird ex-post sowohl der vorlaufzeitübergreifende durchschnittliche Korrelationskoeffizient als auch die Unterschiede für verschiedene Vorlaufzeiten gemessen. Dies ermöglicht der Supply Chain eine grobe ex-post Einschätzung der Korrelationsstärke für unterschiedliche Vorlaufzeiten.

Wie bereits zu Beginn dieses Abschnitts erwähnt, sind die Kennzahlen besonders nützlich bei der Prognose zukünftiger Nachfrage. Dies gilt vor allem dann, wenn die Supply Chain auf Basis einer linearen Regressionsanalyse Rückschlüsse von der ADI auf die zukünftige tatsächliche Nachfrage ziehen will. Umso stärker dabei die Korrelation ist, umso geeigneter sind diese Prognosemethoden. In Kapitel 7 wird dazu im Detail dargelegt, wie die Kennzahlen und die zu erwartende Prognosegenauigkeit zusammenspielen.

5.1.5. Zusammenfassung der Kennzahlen zum statischen Bestellverhalten

In diesem Abschnitt wurden 17 Kennzahlen zur Bewertung eines statischen Bestellverhaltens in vier unterschiedlichen Kategorien vorgestellt. Sie erlauben der Supply Chain eine Charakterisierung verschiedener Aspekte des Bestellverhaltens und ermöglichen somit gleichzeitig eine Einschätzung der Verwendbarkeit der ADI für unterschiedliche betriebswirtschaftliche Aufgaben. Die Kennzahlen beziehen sich auf einen abstrakten Zeitraum zwischen den Zeitpunkten t_1 und t_n . Sie basieren auf der Annahme, dass das Bestellverhalten innerhalb des betrachteten Zeitraums statisch ist. Eine Veränderung des Bestellverhaltens wird entsprechend nicht untersucht. Kennzahlen zur Beschreibung einer solchen Dynamik im Bestellverhalten werden im nächsten Abschnitt erläutert.

Die Bedeutung der einzelnen Kennzahlen ist in Tabelle 5.11 zusammengefasst. Die Kennzahlen sind dabei in die Kategorien Spannweite, Streuung (Durchschnitt und Form) und Korrelation untergliedert. Die Parameter t_1 und t_n einer jeden Kennzahl wurden hier weggelassen, um die Übersichtlichkeit zu verbessern.

Kategorie	Art der Bewertung	Abschnitt	Kennzahlen	Bedeutung
Spannweite		5.1.1	$K_{1,Start}(\mathbf{A})$	<ul style="list-style-type: none"> • Vorlaufzeitrahmen, der die Grenzen des Bestellungseingangs markiert bzw. dessen Länge bewertet
			$K_{1,End}(\mathbf{A})$	
			$K_{1,Range}(\mathbf{A})$	

5. Charakterisierung des Bestellverhaltens

Kategorie	Art der Bewertung	Abschnitt	Kennzahlen	Bedeutung
Streuung	Durchschnitt	5.1.2	$K_{2,\sigma}(D_{Aes})$	<ul style="list-style-type: none"> • Vorlaufzeit übergreifender Durchschnitt der Standardabweichungen bzw. Variationskoeffizienten • Je drei Kennzahlen für Standardabweichungen und Variationskoeffizienten, wobei sich je eine auf die kumuliert vorliegende, ausstehende und anteilig vorliegende Bestellmenge bezieht
			$K_{2,\sigma}(U_{Aes})$	
			$K_{2,\sigma}(X_{Aes})$	
			$K_{2,VK}(D_{Aes})$	
			$K_{2,VK}(U_{Aes})$	
			$K_{2,VK}(X_{Aes})$	
	Form	5.1.3	$K_{3,\sigma,Trend}(D_{Aes})$	<ul style="list-style-type: none"> • Bewertung des Entwicklungstrends der Standardabweichungen und Variationskoeffizienten mit zunehmender Vorlaufzeit • Positiver Wert impliziert größere Standardabweichungen und Variationskoeffizienten mit zunehmender Vorlaufzeit • Je drei Kennzahlen für Standardabweichungen und Variationskoeffizienten, wobei sich je eine auf die kumuliert vorliegende, ausstehende und anteilig vorliegende Bestellmenge bezieht
			$K_{3,\sigma,Trend}(U_{Aes})$	
			$K_{3,\sigma,Trend}(X_{Aes})$	
			$K_{3,VK,Trend}(D_{Aes})$	
			$K_{3,VK,Trend}(U_{Aes})$	
			$K_{3,VK,Trend}(X_{Aes})$	
Korrelation	Durchschnitt	5.1.4	$K_{4,Avg}(D_{Aes})$	<ul style="list-style-type: none"> • Durchschnittliche Korrelationsstärke zwischen vorliegender Bestellmenge zu verschiedenen Vorlaufzeiten und tatsächlicher Nachfrage
	Form		$K_{4,Trend}(D_{Aes})$	<ul style="list-style-type: none"> • Entwicklung der Korrelationsstärke zwischen vorliegender Bestellmenge und tatsächlicher Nachfrage mit zunehmender Vorlaufzeit

Tabelle 5.11.: Kennzahlenrahmenwerk

5.2. Charakterisierung des dynamischen Bestellverhaltens

Die im folgenden vorgestellten Kennzahlen dienen der ex-post Analyse des dynamischen Bestellverhaltens. Es wird also untersucht, ob sich das Bestellverhalten in dem betrachteten Zeitraum in der Vergangenheit bereits verändert hat. Die Kennzahlen decken dabei die gleichen Aspekte (Spannweite, Streuung (Durchschnitt und Form) sowie Korrelation) wie im vergangenen Abschnitt ab. Das Vorgehen zur Berechnung dieser Kennzahlen ist stets das folgende:

1. Der Zeitraum zwischen t_1 und t_n wird in p aufeinanderfolgende überschneidungsfreie gleichgroße Teilmengen aufgeteilt.
2. Die Kennzahlen aus dem letzten Abschnitt werden für jede der p Teilmengen einzeln berechnet.
3. Die Kennzahlen werden mit den Mitteln der Zeitreihenanalyse untersucht; dabei liegt der Fokus auch hier auf der Identifikation von Trends. Die Trendsteigung ist ein Indikator für die ex-post Entwicklung des Bestellverhaltens.




Abbildung 5.6.: Exemplarische Kennzahlberechnung

Abbildung 5.6 illustriert dies für den Anfangspunkt der Spannweite. Die resultierende Kennzahl $K_{1,Dev,Start}(t_1, t_n, A, p)$ beschreibt die Entwicklung des Anfangspunkts. Die neue Kennzahl führt dabei als weiteren Parameter mit p die Anzahl der Teilmengen ein. Es wird hier ohne Einschränkung der Allgemeinheit davon ausgegangen, dass n durch p ohne Rest teilbar ist.⁹

Der Analysefokus liegt in dieser Arbeit auf der Identifikation eines Trends innerhalb des ex-post betrachteten Zeitraums. Der y -Achsenabschnitt und die Trendsteigung können

⁹Falls n nicht durch p teilbar ist, können am Anfang der gesamten Zeitreihe so viele Werte übersprungen werden, dass die Teilbarkeit für die resultierende Zeitreihe gewährleistet ist.

mit den in Kapitel 4 vorgestellten Formeln berechnet werden. Für eine beliebige Kennzahl $K_Q(t_1, t_n, \dots)^{10}$ aus Abschnitt 5.1 gilt dabei:

$$\begin{aligned} \bullet \beta_0(t_1, t_n, \dots, p) &= \frac{\sum_{i=1}^p i^2 \sum_{j=1}^p K_Q\left(t_{\frac{(i-1)n}{p}+1}, t_{\frac{jn}{p}}, \dots\right) - \sum_{i=1}^p i \sum_{j=1}^p j \cdot K_Q\left(t_{\frac{(i-1)n}{p}+1}, t_{\frac{jn}{p}}, \dots\right)}{p \sum_{i=1}^p i^2 - \left(\sum_{i=1}^p i\right)^2} \\ \bullet \beta_1(t_1, t_n, \dots, p) &= \frac{p \sum_{i=1}^p i \cdot K_Q\left(t_{\frac{(i-1)n}{p}+1}, t_{\frac{jn}{p}}, \dots\right) - \sum_{i=1}^p i \sum_{j=1}^p K_Q\left(t_{\frac{(i-1)n}{p}+1}, t_{\frac{jn}{p}}, \dots\right)}{p \sum_{i=1}^p i^2 - \left(\sum_{i=1}^p i\right)^2} \end{aligned}$$

Die Kennzahl $K_{Q,Dev}(t_1, t_n, \dots, p)$ entspricht dabei abermals der Trendsteigung:

$$\bullet K_{Q,Dev}(t_1, t_n, \dots, p) = \beta_1(t_1, t_n, \dots, p)$$

Eine positive Kennzahl impliziert eine Steigerung der entsprechenden Kennzahl in dem ex-post betrachteten Zeitraum. Umgekehrt deutet eine negative Kennzahl auf ein Sinken der Kennzahl hin. Aus $K_{1,Dev,Start}(t_1, t_n, \mathbf{A}, p) < 0$ folgt somit für das obige Beispiel des Anfangspunkts, dass die mit ihm assoziierte Vorlaufzeit in der Vergangenheit rückläufig war und entsprechend Bestellungen kurzfristiger geworden sind. Die Bedeutung eines positiven Trends für die verschiedenen Kennzahlen ist in Tabelle 5.12 zusammengefasst. Die entsprechend entgegengesetzten Effekte ergeben sich dabei für einen negativen Trend. Im Beispiel in Tabelle 5.13 werden illustrativ die dynamischen Kennzahlen zur Streuung der vorliegenden Bestellmenge berechnet.¹¹ Es werden Bestellungen für einen Zeitraum von 16 Zeitpunkten (t_1 bis t_{16}) mit einer Vorlaufzeit von bis zu $e = 3$ analysiert. Zur Berechnung der Kennzahlen wird dieser Zeitraum in vier aufeinanderfolgende Teilmengen bestehend jeweils aus vier Zeitpunkten aufgeteilt: t_1 bis t_4 , t_5 bis t_8 , t_9 bis t_{12} sowie t_{13} bis t_{16} . Für jede dieser vier Teilmengen werden zunächst die Kennzahlen $K_{2,\sigma}(t_1, t_n, D_{Aes})$ und $K_{3,\sigma,Trend}(t_1, t_n, D_{Aes})$ errechnet. Die jeweils vier Kennzahlen werden anschließend ebenfalls einer Trendanalyse unterzogen. Die resultierenden dynamischen Kennzahlen für dieses Beispiel sind $K_{2,Dev,\sigma}(t_1, t_n, D_{Aes}, p = 4) = 1,11$ und $K_{3,Dev,\sigma,Trend}(t_1, t_n, D_{Aes}, p = 4) = 0,17$. Die erste Kennzahl impliziert, dass die vorlaufzeitübergreifende Streuung in dem ex-post betrachteten Zeitraum zugenommen hat. Die zweite dynamische Kennzahl deutet auf einen Anstieg der statischen Kennzahl zur Form der Streuung. Das bedeutet, dass die Streuung bei längeren Vorlaufzeiten im Vergleich zu kürzeren zugenommen hat.

Wie bei den Kennzahlen aus Abschnitt 5.1, für deren Berechnung eine Trendanalyse durchgeführt wurde, kann ein Student-t-Test verwendet werden, um zu überprüfen, ob die Trendsteigung signifikant von 0 abweicht. Die Testgröße T für die beiden Kennzahlen findet sich in der rechten unteren Ecke der Tabelle. Für die Kennzahl zur Entwicklung der Durchschnittsstreuung beträgt sie 10,95 und für die Kennzahl zur Form der Streuung

¹⁰ t_1 und t_n werden hier als Parameter explizit aufgeführt, weil sie für die Berechnung relevant sind.

¹¹Das Beispiel wurde absichtlich auf 16 Zeitpunkte begrenzt, weil die exemplarische Berechnung der dynamischen Kennzahlen und nicht die errechneten Werte selbst im Fokus stehen sollen.

5. Charakterisierung des Bestellverhaltens

Kategorie	Kennzahl	Bedeutung eines positiven Werts
Spannweite	$K_{1,Dev,Start}(t_1, t_n, \mathbf{A}, p)$	<ul style="list-style-type: none"> Die mit dem Anfangs- bzw. Endpunkt verbundene Vorlaufzeit ist gewachsen Entsprechende Bestellungen gingen zunehmend langfristiger ein
	$K_{1,Dev,End}(t_1, t_n, \mathbf{A}, p)$	
	$K_{1,Dev,Range}(t_1, t_n, \mathbf{A}, p)$	<ul style="list-style-type: none"> Die Spannweite zwischen Anfangs- und Endpunkt ist größer geworden
Streuung	$K_{2,Dev,\sigma}(t_1, t_n, D_{\mathbf{Aes}}, p)$	<ul style="list-style-type: none"> Die vorlaufzeitübergreifende durchschnittliche Streuung (Standardabweichung bzw. Variationskoeffizient) hat zugenommen Entsprechende Bestellmengen variierten stärker
	$K_{2,Dev,\sigma}(t_1, t_n, U_{\mathbf{Aes}}, p)$	
	$K_{2,Dev,\sigma}(t_1, t_n, X_{\mathbf{Aes}}, p)$	
	$K_{2,Dev,VK}(t_1, t_n, D_{\mathbf{Aes}}, p)$	
	$K_{2,Dev,VK}(t_1, t_n, U_{\mathbf{Aes}}, p)$	
	$K_{2,Dev,VK}(t_1, t_n, X_{\mathbf{Aes}}, p)$	
	$K_{3,Dev,\sigma,Trend}(t_1, t_n, D_{\mathbf{Aes}}, p)$	<ul style="list-style-type: none"> Die Trendsteigung zur Bewertung der Form der Streuung hat zugenommen Entsprechend ist die Streuung bei längerfristigen Vorlaufzeiten im Vergleich zu kurzfristigen Vorlaufzeiten gewachsen
	$K_{3,Dev,\sigma,Trend}(t_1, t_n, U_{\mathbf{Aes}}, p)$	
	$K_{3,Dev,\sigma,Trend}(t_1, t_n, X_{\mathbf{Aes}}, p)$	
	$K_{3,Dev,VK,Trend}(t_1, t_n, D_{\mathbf{Aes}}, p)$	
	$K_{3,Dev,VK,Trend}(t_1, t_n, U_{\mathbf{Aes}}, p)$	
	$K_{3,Dev,VK,Trend}(t_1, t_n, X_{\mathbf{Aes}}, p)$	
Korrelation	$K_{4,Dev,Avg}(t_1, t_n, D_{\mathbf{Aes}}, p)$	<ul style="list-style-type: none"> Bei oberer Kennzahl: Verstärkung der durchschnittlichen Korrelation zwischen vorliegender Bestellmenge und Nachfrage Bei unterer Kennzahl: Trendsteigung zur Formbewertung ist gewachsen, wodurch die Korrelation bei längerfristigen Vorlaufzeiten im Vergleich zu kurzfristigen zugenommen hat
	$K_{4,Dev,Trend}(t_1, t_n, D_{\mathbf{Aes}}, p)$	

Tabelle 5.12.: Überblick Kennzahlen des dynamischen Bestellverhaltens

D_{Aes}	<i>Wunschlieferzeitpunkt</i>							
	t_1	t_2	t_3	t_4	t_5	t_6	t_7	t_8
$e = 3$	10	10	10	15	5	10	15	10
$e = 2$	30	35	35	35	30	40	40	35
$e = 1$	75	75	70	80	70	75	80	75
$e = 0$	100	105	95	105	100	105	110	100
	t_9	t_{10}	t_{11}	t_{12}	t_{13}	t_{14}	t_{15}	t_{16}
$e = 3$	5	15	20	10	15	20	25	25
$e = 2$	40	35	50	40	50	45	60	65
$e = 1$	85	80	90	80	80	80	90	85
$e = 0$	105	105	115	100	110	110	125	120

	$t_1 \dots t_4$	$t_5 \dots t_8$	$t_9 \dots t_{12}$	$t_{13} \dots t_{16}$
$K_{2,\sigma}(t_1, t_n, D_{\text{Aes}})$	3,61	4,45	5,99	6,81
$K_{3,\sigma,Trend}(t_1, t_n, D_{\text{Aes}})$	-0,84	-0,15	0,20	-0,38
$K_{2,Dev,\sigma}(t_1, t_n, D_{\text{Aes}}, p = 4)$	1,11		T	10,95
$K_{3,Dev,\sigma,Trend}(t_1, t_n, D_{\text{Aes}}, p = 4)$	0,17		T	0,84

Tabelle 5.13.: Beispiel zur Berechnung von dynamischen Kennzahlen

0,84. Bei einem Signifikanzniveau von 10% beträgt der relevante Wert aus der Student-t-Verteilung mit zwei Freiheitsgraden 2,92. Entsprechend weicht die Trendsteigung im ersten Fall signifikant von 0 ab, womit die Hypothese, dass kein Trend vorliegt, zu verwerfen ist. Dies gilt für die zweite Kennzahl nicht. Der Trend weicht nicht signifikant von 0 ab und $K_{3,Dev,\sigma,Trend}(t_1, t_n, D_{\text{Aes}}, p = 4)$ kann manuell auf 0 gesetzt werden.

Außer auf die beschriebenen Trends können die ex-post Daten nach der Unterteilung in mehrere Teilmengen auch auf andere Eigenheiten mit den Methoden der Zeitreihenanalyse untersucht werden. Darauf wird an dieser Stelle verzichtet, um das Kennzahlenrahmenwerk möglichst einfach zu halten. Denkbar ist aber natürlich auch eine Analyse von Saisonalitäten, Zyklen oder anderen zeitreihenbezogenen Eigenheiten.

Zusätzlich zu der Betrachtung des statischen Bestellverhaltens aus Abschnitt 5.1 sollen die Kennzahlen dieses Abschnitts der Supply Chain ermöglichen, eine Dynamik im Bestellverhalten zu erkennen. Veränderungen im Bestellverhalten können so identifiziert und in die Entscheidungen der Supply Chain miteinbezogen werden. So kann die durchschnittliche Standardabweichung $K_{2,\sigma}(t_1, t_n, D_{\text{Aes}})$ beispielsweise relativ hoch sein, die Supply Chain aber trotzdem zu dem Schluss kommen, die entsprechende ADI einzusetzen, weil $K_{2,Dev,\sigma}(t_1, t_n, D_{\text{Aes}}, p)$ stark negativ ist und somit die Streuung im ex-post betrachteten Zeitraum rückläufig war.

5.3. Konstanz der Bestellmengen

Die bisherigen Kennzahlen sind auf die ex-post Messung von Streuung und Korrelation im

Bestellverhalten konzentriert. Die Kennzahlen basieren auf den in Kapitel 3 vorgestellten Durchschnittswerten aus dem verallgemeinerten Auftragsprofil. Hier wurden das arithmetische Mittel, die Standardabweichung und der Variationskoeffizient zur Definition des verallgemeinerten Auftragsprofils vorgestellt. Die Verwendung dieser Werte gründet sich wiederum auf die Annahme, dass die zugrunde liegenden Zeitreihen bis auf zufällige Abweichungen konstant sind, wie in Kapitel 4 erläutert. Eine Zeitreihe ist dabei konstant, wenn sie durch Gleichung 4.1.1 beschrieben wird, wobei die verbleibenden Abweichungen zufällig und identisch unabhängig verteilt sind.¹² Bei der Berechnung von $\mu(t_1, t_n, D_{Aes})$ wird also beispielsweise davon ausgegangen, dass die Zeitreihe der kumuliert vorliegenden Bestellmengen zu einer Vorlaufzeit von e zwischen den Zeitpunkten t_1 und t_n einer konstanten entspricht. Ob diese Annahme auch berechtigt ist, wird bisher nicht überprüft. Die Kennzahlen in diesem Abschnitt sollen dies ermöglichen.

In dem gerade angeführten Beispiel muss also überprüft werden, ob das Modell einer Zeitreihe mit konstanter Nachfrage geeignet ist, um die Zeitreihe $D_{Aet_1}, D_{Aet_2}, \dots, D_{Aet_n}$ abzubilden. Es muss dafür untersucht werden, ob die Abweichungen vom arithmetischen Mittel eine Systematik aufweisen, die durch das Zeitreihenmodell einer konstanten Nachfrage nicht erfasst wird. Eine solche Systematik kann beispielsweise ein Trend sein. Wie in Kapitel 4 dargestellt, ist dann ein anderes Modell zur Beschreibung der Zeitreihe besser geeignet.

Tabelle 5.14 enthält ein Beispiel. Die sechs kumuliert vorliegenden Bestellmengen mit einer Vorlaufzeit von $e = 2$ weisen ein arithmetisches Mittel von $\mu(t_1, t_n, D_{Aes}) = 400,0$ auf. Werden die sechs Werte, die zwischen t_1 und t_6 eingehen und zwischen 350 und 450 variieren, als Zeitreihe betrachtet und als solche mit einem Trend modelliert, ergibt sich hier noch eine Trendsteigung von $\beta_1(t_1, t_n, D_{Aes})=0$. Es liegt also keine Trendsteigung vor. Für die Zeitreihen mit einer Vorlaufzeit von $e = 1$ und $e = 0$ werden bei diesem Modell allerdings Trendsteigungen von 31,4 bzw. 37,1 errechnet.¹³ Der positive Trend wird auch bei Betrachtung der Zeitreihen sofort ersichtlich. Bei beiden Vorlaufzeiten steigert sich die kumuliert vorliegende Bestellmenge monoton von 700 bzw. 1000 zu t_1 bis auf 850 bzw. 1200 zu t_6 . Der positive Trend wird durch die arithmetischen Mittel von 783,3 bzw. 1133,3 nicht erfasst.

D_{Aes}	<i>Wunschlieferzeitpunkt</i>						$\mu(t_1, t_n, D_{Aes})$	$\beta_1(t_1, t_n, D_{Aes})$
	t_1	t_2	t_3	t_4	t_5	t_6		
$e = 2$	450	350	350	450	400	400	400,0	0
$e = 1$	700	750	750	800	850	850	783,3	31,4
$e = 0$	1000	1100	1150	1150	1200	1200	1133,3	37,1

Tabelle 5.14.: Beispiel zur Konstanz der Zeitreihen im verallgemeinerten Auftragsprofil

Innerhalb der Spannweite zwischen Anfangs- und Endpunkt e_{start} bzw. e_{end} gibt es für jede Vorlaufzeit e eine Zeitreihe der kumuliert vorliegenden, ausstehenden und anteilig

¹²Zu den Ausführungen zum Modell konstanter Nachfrage in diesem Abschnitt vgl. u.a. Meyr (2012).

¹³Das Vorliegen eines positiven Trends wird auch durch den in Kapitel 4 vorgestellten Student-t-Test bei einem Signifikanzniveau von 10% bestätigt.

vorliegenden Bestellmenge. Sie beginnen jeweils zum Wunschliefzeitpunkt t_1 und enden bei t_n . In dem Beispiel in Tabelle 5.14 ist dies zur Vorlaufzeit $e = 2$ die Zeitreihe $D_{A2t_1}, D_{A2t_2}, D_{A2t_3}, D_{A2t_4}, D_{A2t_5}, D_{A2t_6}$. Die hier entwickelten Kennzahlen messen vorlaufzeitübergreifend den Anteil an Zeitreihen, für die das konstante Modell eine gute Darstellungsform ist. Die Kennzahlen sollen dabei die kumuliert vorliegende, ausstehende und anteilig vorliegende Bestellmenge getrennt bewerten:

- Die Kennzahl $K_{5,konst}(t_1, t_n, D_{Aes})$ für die kumuliert vorliegenden Bestellmengen
- Die Kennzahl $K_{5,konst}(t_1, t_n, U_{Aes})$ für die ausstehenden Bestellmengen
- Die Kennzahl $K_{5,konst}(t_1, t_n, X_{Aes})$ für die anteilig vorliegenden Bestellmengen

Wenn zwischen Anfangs- und Endpunkt für q Zeitreihen das konstante Modell als geeignet angesehen wird, gilt für die kumuliert vorliegende Bestellmenge:¹⁴

$$K_{5,konst}(t_1, t_n, D_{Aes}) = \frac{q}{K_{1,Range}(t_1, t_n, A)} \quad (5.3.1)$$

In obigem Beispiel in Tabelle 5.14 gilt beispielsweise $K_{5,konst}(t_1, t_n, D_{Aes}) = 33,3\%$, weil die Zeitreihen zu den Vorlaufzeiten von $e = 0$ und $e = 1$ einem positiven Trend unterliegen und deshalb nicht zu dem Modell einer konstanten Nachfrage passen. Einzig für die Zeitreihe mit einer Vorlaufzeit von $e = 2$ ist das konstante Modell geeignet.

Damit das Modell konstanter Nachfrage geeignet ist, darf aber nicht nur kein Trend vorliegen. Weitere Eigenschaften, die das Modell konstanter Nachfrage ungeeignet machen, sind beispielsweise Saisonalitäten, Zyklen oder sporadische Nachfrage. Alle diese und noch andere Eigenschaften werden durch das Modell konstanter Nachfrage nicht erfasst. Das Modell konstanter Nachfrage ist für eine Zeitreihe genau dann nicht geeignet, wenn die Abweichungen darin nicht zufällig und identisch unabhängig verteilt sind. Weisen die Abweichungen eine Systematik auf, ist ein anderes Modell, das diese berücksichtigt, besser geeignet. Wie Kendall und Ord (1990, S. 18–26) beschreiben, existiert kein einzelner Test, der alle denkbaren Systematiken erkennt und so gleichzeitig zeigt, dass die Abweichungen zufällig und identisch unabhängig verteilt sind. Vielmehr muss für jede Systematik individuell überprüft werden, ob die Zeitreihe sie aufweist. Es muss also separat getestet werden, ob die Zeitreihen eventuell einem Trend, einer Saisonalität oder einer anderen Systematik unterliegen, die eine Konstanz ausschließen. Kann durch einen Test allerdings nachgewiesen werden, dass die Zeitreihe eine solche Systematik aufweist, dann ist die Annahme, dass das Modell konstanter Nachfrage zur Darstellung der Zeitreihe geeignet ist, zu verwerfen. Die Kennzahlen sollen den Anteil an Zeitreihen zwischen Anfangs- und Endpunkt wiedergeben, für die keine Systematik nachgewiesen werden konnte und somit die Hypothese aufrechterhalten werden kann, dass die Zeitreihe konstant ist. Die Auswahl der Eigenschaften, auf die die Zeitreihen überprüft werden sollen, ist vom Anwender unter Berücksichtigung seiner spezifischen Anforderungen zu treffen.

¹⁴Für die ausstehende und anteilig vorliegende Bestellmenge wird die Zeitreihe zum Anfangspunkt abermals nicht berücksichtigt, da sie stets 0 bzw. 100% ist.

Vorlaufzeit	Trend	Saisonalität	Sporadischer Bedarf	Konstanz ausgeschlossen	Konstanz möglich
$e_{end} = 15$			✓	✓	
$e = 14$			✓	✓	
$e = 13$			✓	✓	
$e = 12$	✓			✓	
$e = 11$	✓			✓	
$e = 10$					✓
$e = 9$					✓
$e = 8$					✓
$e = 7$	✓			✓	
$e = 6$	✓	✓		✓	
$e_{start} = 5$	✓	✓		✓	
Konstantes Zeitreihenmodell geeignete Darstellungsform:					3/11
$K_{5,konst}(t_1, t_n, D_{Aes})$					27,3%

Tabelle 5.15.: Beispiel Anteil konstanter Zeitreihen

In Tabelle 5.15 ist die Berechnung exemplarisch für die kumuliert vorliegende Bestellmenge dargestellt. Der Endpunkt der Nachfrage liegt bei $e_{end} = 15$ und der Anfangspunkt bei $e_{start} = 5$. Die Zeitreihen wurden mit dem bereits erläuterten Test auf einen Trend und mit den im Anschluss beschriebenen Tests auf Saisonalität bzw. sporadischen Bedarf untersucht. Die Zeitreihen zu Vorlaufzeiten von 13–15 wurden als sporadisch bewertet. Für die Zeitreihen mit Vorlaufzeiten von 5, 6, 7, 11 und 12 wurde ein Trend nachgewiesen. Zusätzlich unterliegen die Zeitreihen mit Vorlaufzeiten von 5 und 6 einer Saisonalität. Für diese acht Zeitreihen kann also das konstante Zeitreihenmodell verworfen werden. Es bleiben die drei Zeitreihen mit Vorlaufzeiten von 8 bis 10, für die keine der Eigenschaften nachweisbar war. Für diese 3 Zeitreihen muss die Annahme, dass das Modell konstanter Nachfrage als Darstellungsform geeignet ist, nicht verworfen werden. Die Kennzahl nimmt in diesem Beispiel also den Wert 27,3% an, weil für $q = 3$ von 11 Zeitreihen Konstanz nicht ausgeschlossen werden konnte.

Für den Nachweis der verschiedenen Eigenschaften existieren statistische Tests. Der in Abschnitt 4.1.2 vorgestellte Student-t-Test kann beispielsweise verwendet werden, um einen Trend zu identifizieren. Es werden an dieser Stelle nun zusätzlich mögliche Vorgehensweisen zum Nachweis von Saisonalitäten und sporadischer Nachfrage vorgestellt. Weitere Verfahren für andere Systematiken werden an dieser Stelle nicht dargestellt, weil auf sie in dieser Arbeit nicht wieder zurückgegriffen wird.¹⁵

Wie von Kendall u.a. (1983, S. 649ff.) sowie Kendall und Ord (1990, S. 96ff.) erwähnt, können Saisonalitäten über die Identifikation von Autokorrelationen nachgewiesen werden. Dafür muss ein Modell zur Abbildung der Zeitreihe benutzt werden, das keine Saisona-

¹⁵Kendall und Ord (1990, S.18–26) testen beispielsweise noch, ob Systematiken bei den Wendepunkten und Phasenlängen einer Zeitreihe vorhanden sind. Details zur Definition von Wendepunkten und Phasenlängen finden sich ebenfalls bei Kendall und Ord (1990, S.18–26).




Abbildung 5.7.: Autokorrelation bei vorliegender Saisonalität

litäten berücksichtigt. Dies kann beispielsweise das konstante Zeitreihenmodell sein, das durch das arithmetische Mittel der ex-post beobachteten Werte abgeschätzt werden kann. Unterliegt die Zeitreihe einer Saisonalität, müssen die verbleibenden Abweichungen eine Autokorrelation aufweisen. Der Grad der Autokorrelation entspricht dabei der Anzahl Perioden bis zur Wiederkehr der Saisonalität. Wird beispielsweise eine Saisonalität bei den Quartals- oder Monatswerten auf jährlicher Basis erwartet, so muss jede vierte bzw. zwölfte Abweichung Ähnlichkeiten aufweisen. Es liegt dann also Autokorrelation vierten bzw. zwölften Grades vor. In Abbildung 5.7 ist dies für Quartalszahlen über drei Jahre illustriert. Die Zeitreihe ist durch unterschiedliche Zeichen markiert, wobei identischen Quartalen dasselbe Zeichen zugeordnet ist. Es ist leicht zu erkennen, dass jeder vierte Wert eine ähnliche Abweichung vom arithmetischen Mittel aufweist, das als Linie in die Zeitreihe eingebettet ist. Das bedeutet auch, dass die gleichen Quartale ähnliche Abweichungen aufweisen. Die Pfeile deuten dabei diese Autokorrelation vierten Grades an. Es kommt also zu Autokorrelation bei nicht beachteten Saisonalitäten. Autokorrelation kann mit den in Kapitel 4 genannten Verfahren nachgewiesen werden. Insbesondere der Breusch-Godfrey-Test¹⁶ scheint dafür geeignet.¹⁷

In Kapitel 4 wurde auch dargestellt, dass das arithmetische Mittel ungeeignet ist für die Modellierung von Zeitreihen mit sporadischem Bedarf.¹⁸ Wie beschrieben, existiert keine Standarddefinition für diese Form von Zeitreihen. Das einfachste Vorgehen zur Überprüfung dieser Eigenschaft untersucht den Anteil an Wunschlieferszeitpunkten, zu denen die

¹⁶Vgl. Breusch (1979) und Godfrey (1978, 1996).

¹⁷Ein alternatives Testverfahren zum Nachweis von Saisonalitäten wird von Kendall und Ord (1990, S. 24–26) vorgestellt. Es wird hier nicht vorgestellt, da es im weiteren Verlauf der Arbeit nicht wieder verwendet wird.

¹⁸Gleiches wurde bereits von Silver u.a. (1998, S. 127ff.), Nowack (2005) sowie Tempelmeier (2008, S. 86ff.) für das Verfahren der exponentiellen Glättung festgestellt.

Zeitreihe den Wert 0 annimmt. Übersteigt dieser einen festzusetzenden Grenzwert, kann die Zeitreihe als eine mit sporadischem Bedarf bewertet werden. Nowack (2005) zitiert ein solches Kriterium mit einem Grenzwert von 50%.

Zu den Kennzahlen $K_{5,konst}(t_1, t_n, D_{Aes})$, $K_{5,konst}(t_1, t_n, U_{Aes})$ und $K_{5,konst}(t_1, t_n, X_{Aes})$ können zusätzlich auch folgende drei dynamische Kennzahlen definiert werden:

1. $K_{5,Dev,konst}(t_1, t_n, D_{Aes}, p)$
2. $K_{5,Dev,konst}(t_1, t_n, U_{Aes}, p)$
3. $K_{5,Dev,konst}(t_1, t_n, X_{Aes}, p)$

Das Vorgehen zur Berechnung ist analog zu dem in Abschnitt 5.2, das in Abbildung 5.6 illustriert ist. Zunächst wird der Zeitraum zwischen t_1 und t_n in p aufeinanderfolgende überschneidungsfreie gleichgroße Teilmengen aufgeteilt. Die drei Kennzahlen $K_{5,konst}(t_1, t_n, D_{Aes})$, $K_{5,konst}(t_1, t_n, U_{Aes})$ und $K_{5,konst}(t_1, t_n, X_{Aes})$ werden anschließend für jede dieser p Teilmengen individuell berechnet. Die p gleichen Kennzahlen können als Zeitreihe betrachtet werden, da sie aus überschneidungsfreien und aufeinanderfolgenden Teilmengen zwischen t_1 und t_n resultieren. Die neuen Kennzahlen entsprechen der Trendsteigung über diese Zeitreihen. Eine positive Kennzahl bedeutet, dass bei Betrachtung des Verlaufs über die p Teilmengen für einen zunehmenden Anteil an Zeitreihen eine Konstanz nicht ausgeschlossen werden kann. Das Modell konstanter Nachfrage erscheint so für einen größeren Anteil an Zeitreihen geeignet. Umgekehrt kann bei einem negativen Trend von einem Rückgang des Anteils konstanter Zeitreihen ausgegangen werden.

Die Kennzahlen dienen der Kontrolle der Werte aus dem verallgemeinerten Auftragsprofil. Die Supply Chain kann mit den Kennzahlen aus diesem Abschnitt prüfen, wie hoch der Anteil systematischer Fehler bei diesen Werten ist, bevor sie diese für Planungsaufgaben verwendet. Es wird dabei untersucht, ob die Nachfrage im ex-post betrachteten Zeitraum zu den verschiedenen Vorlaufzeiten konstant ist oder eine bisher nicht erkannte Systematik aufweist.

5.4. Berechnung Kennzahlen für ausgewählte Beispiele

Für die beispielhafte Berechnung der Kennzahlen werden die folgenden vier Datensätze verwendet, um unterschiedliches Bestellverhalten darzustellen:

1. Praxisdaten aus der Industrie für feuerfeste Materialien – *FIRE*: Nachfragewerte einer Aggregationsebene stehen für einen Zeitraum von 4 Jahren auf monatlicher Basis mit Bestelldaten ab einer Vorlaufzeit von 6 Monaten zur Verfügung.
2. Praxisdaten aus der Baustoffindustrie – *BUILD*: Für den Zeitraum von einem Jahr liegen detaillierte Bestellinformationen vor. Sie beinhalten das Datum des Bestellungseingangs sowie des Wunschliefertermins. Neben der bestellten Menge geben die Daten in anonymisierter Form den Kunden, das Produkt sowie die Bestellungseingangsstelle wieder.

3. Praxisdaten aus der Chemieindustrie – *CHEM*: Analog zum vorherigen Beispiel liegen detaillierte Bestellsdaten inklusive Details zu den Kunden, Produkten, Bestellungseingangsstellen, dem Datum des Bestellungseingangs sowie dem Wunschliefertermin vor. Die Daten liegen für einen Zeitraum von neun Monaten vor.
4. Daten aus Kekre u.a. (1990) – *KEKRE*: Der Datensatz enthält die Nachfrage zu 15 Wunschlieferzeitpunkten mit Bestellungseingängen ab einer Vorlaufzeit von 7. Der Datensatz wurde synthetisch erzeugt und als Anwendungsbeispiel auf die in Kekre u.a. (1990) vorgestellte ADI-basierte Prognosemethode zugeschnitten.




Abbildung 5.8.: Durchschnitt und Streuung bei den kumuliert vorliegenden Bestellmengen

Kursiv angeführt sind die hier verwendeten Abkürzungen für die Datensätze. In Abbildung 5.8 werden die in Kapitel 3 vorgestellten arithmetischen Mittel $\mu(t_1, t_n, D_{\text{Aes}})$ und Standardabweichungen $\sigma(t_1, t_n, D_{\text{Aes}})$ für die vier Beispieldatensätze aufgeführt. Analog zu Abbildung 3.6 markieren die grauen Balken die Werte für verschiedene Vorlaufzeiten. *BUILD* wird für eine ausgewählte Aggregationsebene auf Wochenbasis, *CHEM* auf Tagesbasis betrachtet. Das Bestellverhalten unterscheidet sich augenscheinlich stark. Im Fall von *CHEM* geht ein Großteil der Nachfrage kurzfristig mit einer Vorlaufzeit von 0–3 Ta-

gen ein. *BUILD* erhält größere Bestellungen schon mit einer Vorlaufzeit von 3–5 Wochen. *FIRE* hat mit 6 Monaten den langfristigsten Bestellungseingang der Praxisdatensätze. Die Streuung ist hier 2–4 Monate vor dem Wunschliefertermin am stärksten. *KEKRE* weist eine geringe Streuung bei einem über 8 Zeiteinheiten verteilten Bestellungseingang auf.

In den folgenden Abschnitten werden nun die Kennzahlen zur Spannweite, Streuung, Korrelation und Konstanz berechnet. Dabei werden die Kennzahlen aus Abschnitt 5.1 und 5.2 jeweils in einem Abschnitt betrachtet. Die Kennzahlen, die auf einem Trend basieren, wurden einem Student-t-Test mit einem Signifikanzniveau von 10% unterzogen. War die Abweichung der Steigung von 0 nicht signifikant, wurde die Kennzahl manuell auf 0 gesetzt.

5.4.1. Kennzahlen der Spannweite

Abbildung 5.9 zeigt die Spannweite der Praxisdatensätze.¹⁹ Der Anfangspunkt aller Beispiele liegt bei einer Vorlaufzeit von 0. Das bedeutet, die Supply Chains müssen bis zum Wunschlieferzeitpunkt selbst mit dem Eingang weiterer Bestellungen rechnen und dies in ihren Planungen berücksichtigen. Die Endpunkte variieren zwischen 35 Tagen (*CHEM*), 13 Wochen (*BUILD*) und 6 Monaten (*FIRE*). *FIRE* hat damit die langfristigsten und *CHEM* die kurzfristigsten Vorlaufzeiten bei den Bestellungseingängen der drei Praxisdatensätze. Die Supply Chain zu dem Beispieldatensatz *FIRE* kann entsprechend mit der vorliegenden ADI am langfristigsten planen. Ihr liegt bereits ein halbes Jahr im Voraus ein Teil der Nachfrage vor. Im Fall von *BUILD* und *CHEM* ist dieser Zeithorizont deutlich kürzer.

Wie zu erwarten, variieren die Vorlaufzeiten der verschiedenen Unternehmen stark. Dabei sollten die Vorlaufzeiten immer vor dem Hintergrund der Produktionsdauer und dem angestrebten Entkopplungspunkt betrachtet werden. Dieser Zusammenhang wird im anschließenden Kapitel detailliert untersucht.

Am Beispiel des *CHEM*-Datensatzes kann das Problem von Ausreißern in den Vorlaufzeiten der Bestellungseingänge sehr gut dargestellt werden. Obwohl >99,7% der Bestellmenge mit einer Vorlaufzeit von 0–4 Tagen eingeht, erstreckt sich die Spannweite über einen Zeitrahmen von 0–35 Tagen. Bereits in Abschnitt 5.1.1 wurde dargestellt, wie mit diesem Problem umgegangen werden kann. Anstatt die minimale und maximale Vorlaufzeit bei der Definition der Spannweite zu betrachten, müssen Quantile der Bestellmenge für die Spezifikation des Anfangs- und Endpunkts verwendet werden. Wird für den *CHEM*-Datensatz beispielsweise als Anfangspunkt die Vorlaufzeit gewählt, zu der durchschnittlich 99% und als Endpunkt die Vorlaufzeit, zu der durchschnittlich 1% der Bestellmenge vorliegt, dann markiert die Spannweite hier eine Vorlaufzeit von 0–4 Tagen. Einzelne kleine Bestellungen mit besonders langen oder kurzen Vorlaufzeiten fallen so aus der Betrachtung. Für die Supply Chain hat diese Betrachtung den Vorteil, dass sie sich bei ihren Planungen auf den wesentlichen Teil des Bestellungseingangs konzen-

¹⁹Die graue Fläche im Hintergrund soll die Skalen unterschiedlicher zeitlicher Dimensionen vergleichbar machen. 15 Wochen entsprechen so ungefähr 3,5 Monaten.





Abbildung 5.9.: Kennzahlen zur Spannweite der Praxisdatensätze

Abbildung 5.10.: Kennzahlen zur Spannweite des *KEKRE*-Datensatzes

trieren kann. Einige wenige Bestellungen werden zwar so nicht mit eingeplant, da sie aber nur einen geringen Anteil des Geschäfts ausmachen, sind sie für die Supply Chain eventuell auch nicht so wichtig. In der folgenden Analyse wird deshalb eine einzelne Bestellung im *CHEM*-Datensatz mit einer Vorlaufzeit von 35 Tagen übergangen, wodurch die Spannweite bereits auf 12 Tage reduziert wird.

In Abbildung 5.10 ist zusätzlich die Spannweite des *KEKRE*-Datensatzes illustriert. Sie liegt zwischen 0 und 7 Zeiteinheiten. Tabelle 5.16 enthält die Kennzahlen zu einem dynamischen Bestellverhalten der vier Datensätze. Es wurden unterschiedliche p -Werte für eine möglichst gleichmäßige Aufteilung der Datensätze gewählt.

Im *FIRE*- und *KEKRE*-Datensatz sind keine Veränderungen von Anfangspunkt, Endpunkt oder Spannweite zu beobachten. Die Kennzahlen nehmen alle den Wert 0 an. Auch für das *CHEM* und *BUILD*-Beispiel ist keine Veränderung des Anfangspunkts zu erkennen. Allerdings hat sich hier der Endpunkt und damit bei gleichem Anfangspunkt entsprechend die Spannweite verändert. Bei *BUILD* gilt $K_{1,Dev,End}(t_1, t_n, \mathbf{A}, p) < 0$, was ex-post einen niedrigeren Endpunkt impliziert. Die Vorlaufzeit der langfristigen Bestellungen wurde zunehmend kürzer. Die entsprechenden Kunden haben also mit kürzeren

	p	$K_{1,Dev,Start}(t_1, t_n, \mathbf{A}, p)$	$K_{1,Dev,End}(t_1, t_n, \mathbf{A}, p)$	$K_{1,Dev,Range}(t_1, t_n, \mathbf{A}, p)$
<i>FIRE</i>	6	0	0	0
<i>BUILD</i>	6	0	-0,857	-0,857
<i>CHEM</i>	10	0	0,388	0,388
<i>KEKRE</i>	3	0	0	0

Tabelle 5.16.: Kennzahlen zur Spannweite für ein dynamisches Bestellverhalten

Vorlaufzeiten bestellt. Die Supply Chain muss diese Entwicklung gegebenenfalls beachten, wenn sie die ADI mit diesen langfristigen Vorlaufzeiten in ihre Pläne eingebunden hat. Umgekehrt ist die Situation bei *CHEM*. Hier gilt $K_{1,Dev,End}(t_1, t_n, \mathbf{A}, p) > 0$. Das bedeutet, dass sich bei den langfristigen Bestellungen die Vorlaufzeit gesteigert hat.

5.4.2. Kennzahlen zur Streuung

In Tabelle 5.17 sind die durchschnittlichen Standardabweichungen und Variationskoeffizienten für die vier Datensätze enthalten. Zusätzlich sind die Kennzahlen für die kumuliert vorliegende Bestellmenge durch gestrichelte Linien in Abbildung 5.11 aufgeführt. Bei der folgenden Analyse und Interpretation der Daten wird zunächst nicht berücksichtigt, dass sich diese auf unterschiedliche zeitliche Dimensionen (Tage, Wochen bzw. Monate) beziehen. Am Ende dieses Abschnitts wird der Einfluss unterschiedlicher zeitlicher Dimensionen für die Datensätze von *BUILD* und *CHEM* analysiert.

Es muss außerdem betont werden, dass die absoluten Streuungswerte immer vor dem Hintergrund der Durchschnittswerte und der damit verbundenen Maßeinheit betrachtet werden sollten. Eine Standardabweichung von 100.000 fällt bei einem Durchschnittswert von 200.000 stärker ins Gewicht als bei einem von 1.000.000. Außerdem basieren die Datensätze auf verschiedenen Maßeinheiten, die sich nicht vereinheitlichen lassen. Die Datensätze sind deshalb nur begrenzt vergleichbar. Auffällig ist allerdings, dass der synthetische Datensatz von *KEKRE* deutlich weniger streut als die drei untersuchten Praxisdatensätze *FIRE*, *BUILD* und *CHEM*. Dies betrifft sowohl die absolute als auch die relative Streuung. Bereits in Abbildung 5.8 war dies ersichtlich und die Kennzahlen aus Tabelle 5.17 verdeutlichen diesen Umstand. Sie sind alle wesentlich niedriger als die entsprechenden Kennzahlen aus den Praxisdatensätzen. Die synthetischen Daten unterscheiden sich also signifikant in Bezug auf die Streuung von den vorliegenden Praxisdaten. Ein wesentlicher Grund für diesen Unterschied ist wahrscheinlich der Hintergrund, vor dem die Daten von *KEKRE* erzeugt wurden. Sie wurden als Anwendungsbeispiel für eine von Kekre u.a. (1990) entwickelte ADI-basierte Prognosemethode synthetisiert. Die Annahme liegt nahe, dass die Daten auf diese Methode zugeschnitten wurden, um möglichst vorteilhafte Ergebnisse zu präsentieren. Wie die Ausführungen in den Kapiteln 7 und 8 noch zeigen werden, eignen sich diese Methoden besonders bei einer niedrigen Streuung der ADI.

Der Datensatz *FIRE* hat ähnliche Streuungswerte für die kumuliert vorliegende Be-

	<i>FIRE</i>	<i>BUILD</i>	<i>CHEM</i>	<i>KEKRE</i>
$K_{2,\sigma}(t_1, t_n, D_{Aes})$	1681	98658	509771	2,1
$K_{2,\sigma}(t_1, t_n, U_{Aes})$	1528	184302	1091777	1,9
$K_{2,\sigma}(t_1, t_n, X_{Aes})$	17,3%	10,9%	16,2%	1,5%
$K_{2,VK}(t_1, t_n, D_{Aes})$	51,4%	362,5%	477,9%	7,6%
$K_{2,VK}(t_1, t_n, U_{Aes})$	51,0%	59,1%	85,9%	6,5%
$K_{2,VK}(t_1, t_n, X_{Aes})$	52,8%	375,8%	763,1%	7,5%

Tabelle 5.17.: Durchschnittsstreuung der Datensätze

stellmenge $K_{2,\sigma}(t_1, t_n, D_{Aes})$ sowie die ausstehende Bestellmenge $K_{2,\sigma}(t_1, t_n, U_{Aes})$, wie in Tabelle 5.17 aufgeführt. Die beiden anderen Praxisdatensätze *BUILD* und *CHEM* unterscheiden sich hier stärker. Ein Grund dafür sind bei *BUILD* und *CHEM* auch die längeren Vorlaufzeiten, zu denen nur eine geringe Bestellmenge kumuliert vorliegt, die wenig streut. Sie senken den durchschnittlichen Wert deutlich. Die ausstehenden Bestellmengen sind zu diesen längeren Vorlaufzeiten dagegen hoch, da nur wenige Bestellungen eingegangen sind. Die Streuung dieser ausstehenden Mengen ist dann auch stärker, was den Durchschnittswert steigert.

Die Kennzahlen zur Streuungsform in Tabelle 5.18 verdeutlichen die Unterschiede zu verschiedenen Vorlaufzeiten. Die entsprechenden Trendgeraden sind für die kumuliert vorliegende Bestellmenge in Abbildung 5.11 als durchgezogene Linie eingezeichnet.

	<i>FIRE</i>	<i>BUILD</i>	<i>CHEM</i>	<i>KEKRE</i>
$K_{3,\sigma,Trend}(t_1, t_n, D_{Aes})$	0	-17191	-103466	-0,12
$K_{3,\sigma,Trend}(t_1, t_n, U_{Aes})$	-98	10466	0	0,29
$K_{3,\sigma,Trend}(t_1, t_n, X_{Aes})$	-1,5%	-2,0%	-2,7%	0
$K_{3,VK,Trend}(t_1, t_n, D_{Aes})$	15,5%	59,6%	87,7%	2,8%
$K_{3,VK,Trend}(t_1, t_n, U_{Aes})$	-20,7%	-3,8%	-5,5%	-2,3%
$K_{3,VK,Trend}(t_1, t_n, X_{Aes})$	16,5%	66,1%	113,0%	3,7%

Tabelle 5.18.: Streuungsform der Datensätze

In den meisten Fällen unterliegt die Streuung einem Trend. Dieser ist hier für die Standardabweichung in 3 von 4 Fällen bei der kumuliert und anteilig vorliegenden Bestellmenge negativ. Das bedeutet, dass bei kürzeren Vorlaufzeiten eine höhere Standardabweichung zu beobachten ist als bei den längeren Vorlaufzeiten. Dies kann auch dadurch erklärt werden, dass zu den längeren Vorlaufzeiten oft deutlich niedrigere Bestellmengen vorliegen, die entsprechend weniger streuen. Bei einer Analyse der Streuung sollten Durchschnitts- und Formkennzahlen im Zusammenhang betrachtet werden, um ein Verständnis für die Streuungsentwicklung zu erlangen. Für die ausstehenden Bestellmengen, die mit zunehmender Vorlaufzeit ansteigen, ist bei 2 von 4 Datensätzen eine positive Steigung zu erkennen.

Die Situation sieht bei den Variationskoeffizienten anders aus. Bei allen Datensätzen




Abbildung 5.11.: Illustration der Streuungskennzahlen

weist die ausstehende Bestellmenge einen negativen und die kumuliert sowie anteilig vorliegende Bestellmenge einen positiven Trend auf. Dies begründet sich durch den inversen Einfluss der Bestellmengen. Die ausstehende Bestellmenge fällt mit kürzer werdenden Vorlaufzeiten. Umgekehrt ist die Situation für die kumuliert und anteilig vorliegende Bestellmenge. Da sich die Durchschnittsbestellmenge im Nenner der Variationskoeffizienten befindet, hat sie einen inversen Effekt auf den Variationskoeffizienten. Niedrige Durchschnittsmengen steigern den Variationskoeffizienten. Abbildung 5.12 illustriert dies für den *BUILD*-Datensatz. Der linke Graph enthält Standardabweichung und Durchschnittsmenge für die verschiedenen Vorlaufzeiten.²⁰ Die besonders niedrigen Durchschnittsmengen bei den längsten Vorlaufzeiten sind ein Grund für die entsprechend hohen Variationskoeffizienten. Die Variationskoeffizienten sind im rechten Graph mit entsprechenden Durchschnitts- und Formkennzahlen dargestellt. Die Steigung der Trendgerade beträgt in diesem Beispiel $K_{3,VK,Trend}(t_1, t_n, X_{Aes}) = 66,1\%$.

Die Supply Chains haben mit diesen Kennzahlen die Möglichkeit, die Streuung im Bestellverhalten zu analysieren, bevor sie diese Informationen für ihre Planung verwenden. Eine höhere Volatilität im Bestellverhalten bedeutet für die Supply Chain, dass sie ihre Planung flexibler gestalten muss, um Schwankungen gegebenenfalls ausgleichen zu können.

²⁰Die y-Achse hat eine logarithmische Skalierung.




Abbildung 5.12.: Variationskoeffizient des *BUILD*-Datensatzes für die anteilig vorliegende Bestellmenge

nen. Besonders starke Schwankungen können den Einsatz von Bestellinformationen für die Planung vollkommen ungeeignet erscheinen lassen. Die Kennzahlen zur durchschnittlichen Streuung erlauben der Supply Chain hier eine allgemeine vorlaufzeitübergreifende Bewertung der Streuung. Im *BUILD*-Beispiel impliziert $K_{2,VK}(t_1, t_n, X_{Aes}) = 375,8\%$ dabei eine starke relative Streuung. Die Supply Chain kann zu dem Schluss kommen, auf den Einsatz der ADI für die Planung zu verzichten. Die Kennzahl zur Form der Streuung $K_{3,VK,Trend}(t_1, t_n, X_{Aes}) = 66,1\%$ zeigt ihr allerdings zusätzlich, dass große Unterschiede in der relativen Streuung bestehen. Mit zunehmender Vorlaufzeit ist eine höhere Streuung zu erwarten. Der ADI-Einsatz kann nun für kurze Vorlaufzeiten geeignet sein, da die relative Streuung, wie zusätzlich in Abbildung 5.12 illustriert, hier niedrig ist. Die Verwendung der ADI bei längeren Vorlaufzeiten ist dann hingegen ungeeignet. Betrachtet die Supply Chain also die verschiedenen Kennzahlen zur Streuung kombiniert, kann sie ungefähr einschätzen, für welche Vorlaufzeiten der ADI-Einsatz in der Planung nützlich bzw. ungeeignet ist.

Die Streuungskennzahlen zu einem dynamischen Bestellverhalten finden sich in Tabelle 5.19. Genauso wie die Streuungskennzahlen zu einem statischen Bestellverhalten der Supply Chain eine grobe Einschätzung erlauben, wie stark die Volatilität im Bestellverhalten für verschiedene Vorlaufzeiten ist, helfen diese Kennzahlen, ex-post Veränderungen in diesem Verhalten zu identifizieren.

Die Kennzahlen zur durchschnittlichen Streuung $K_{2,Dev,(\sigma/VK)}$ zeigen, ob die Streuung im Zeitverlauf zugenommen hat. Ein positiver Wert impliziert beispielsweise einen Zuwachs an Streuung, den die Supply Chain in ihrer Planung berücksichtigen sollte. In Bezug auf die absolute Streuung ist ein solcher Anstieg bei *FIRE* und *BUILD* für die kumuliert und anteilig vorliegende Bestellmenge sowie bei *CHEM* für die ausstehende Bestellmenge zu beobachten. Im *FIRE*-Beispiel hat die Kennzahl für die kumuliert vorliegende Bestellmenge beispielsweise folgenden positiven Wert: $K_{2,Dev,\sigma}(t_1, t_n, D_{Aes}, p) = 119$. Ein Rückgang ist bei *CHEM* sowie dem synthetischen *KEKRE*-Datensatz bei der anteilig vorliegenden Bestellmenge zu erkennen. Die Veränderungen der relativen Streuung, die sich auf den Variationskoeffizienten beziehen, finden sich ebenfalls in Tabelle 5.19. Je

	<i>FIRE</i>	<i>BUILD</i>	<i>CHEM</i>	<i>KEKRE</i>
p	6	6	10	3
$K_{2,Dev,\sigma}(t_1, t_n, D_{Aes}, p)$	119	7192	0	0
$K_{2,Dev,\sigma}(t_1, t_n, U_{Aes}, p)$	0	0	38163	0
$K_{2,Dev,\sigma}(t_1, t_n, X_{Aes}, p)$	1,2%	1,1%	-0,7%	-0,2%
$K_{2,Dev,VK}(t_1, t_n, D_{Aes}, p)$	0	-6,0%	0	0
$K_{2,Dev,VK}(t_1, t_n, U_{Aes}, p)$	15,7%	6,1%	-3,0%	0
$K_{2,Dev,VK}(t_1, t_n, X_{Aes}, p)$	0	-9,9%	11,2%	0
$K_{3,Dev,\sigma,Trend}(t_1, t_n, D_{Aes}, p)$	53,5	-2133	0	0
$K_{3,Dev,\sigma,Trend}(t_1, t_n, U_{Aes}, p)$	0	3017	-18029	0
$K_{3,Dev,\sigma,Trend}(t_1, t_n, X_{Aes}, p)$	0,5%	-0,4%	-0,9%	0
$K_{3,Dev,VK,Trend}(t_1, t_n, D_{Aes}, p)$	0	0	-2,3%	-1,0%
$K_{3,Dev,VK,Trend}(t_1, t_n, U_{Aes}, p)$	-10,0%	-0,9%	1,5%	0,6%
$K_{3,Dev,VK,Trend}(t_1, t_n, X_{Aes}, p)$	0	1,7%	-3,9%	0

Tabelle 5.19.: Kennzahlen zur Streuung für ein dynamisches Bestellverhalten

höher dabei der Wert der Kennzahl ist, desto stärker ist die Veränderung der Streuung, die die Supply Chain beachten muss.

Zusätzlich zeigen die dynamischen Kennzahlen zur Streuungsform $K_{3,Dev,(\sigma/VK),Trend}$, ob sich die Unterschiede in der Streuung zwischen kurz- und langfristigen Vorlaufzeiten verändert haben. Ist die Kennzahl positiv, hat sich dieser Unterschied vergrößert. Bezogen auf die absolute Streuung liegt eine solche Situation beispielsweise bei *FIRE* für die kumuliert und anteilig vorliegende Bestellmenge und bei *BUILD* für die ausstehende Bestellmenge vor. Die umgekehrte Situation ist bei der kumuliert und anteilig vorliegenden Bestellmenge beim *BUILD*-Beispiel sowie der ausstehenden und anteilig vorliegenden Bestellmenge beim *CHEM*-Beispiel zu beobachten. Diese Entwicklung muss eine Supply Chain berücksichtigen, wenn sie die ADI verwendet. Sinkt zum Beispiel der Streuungsunterschied zwischen lang- und kurzfristigen Vorlaufzeiten bei einer unveränderten Durchschnittsstreuung, dann hat sich die Streuung bei den kurzfristigen Vorlaufzeiten gesteigert, während sie bei den langfristigen gefallen ist. Die Supply Chain muss nun überprüfen, für welche Vorlaufzeiten und Planungsaufgaben die Nutzung der ADI geeignet ist. Es gilt auch hier: Je höher die Kennzahl ist, desto stärker war die Veränderung. Ist die dynamische Kennzahl 0, konnte ex-post keine solche Veränderung beobachtet werden. Abschließend wird hier noch der Einfluss unterschiedlicher zeitlicher Dimensionen auf die Streuung bei der kumuliert vorliegenden Bestellmenge untersucht. Abbildung 5.13 zeigt die durchschnittlichen Bestellmengen und die Standardabweichungen für die Datensätze von *BUILD* und *CHEM* bei zwei unterschiedlichen zeitlichen Aggregationsebenen: *BUILD* auf Wochen- und Monatsbasis sowie *CHEM* auf Tages- und Wochenbasis. Abbildung 5.14 und 5.15 illustrieren die Veränderung der Kennzahlen bei einem Wechsel der zeitlichen Aggregationsebene.

5. Charakterisierung des Bestellverhaltens




Abbildung 5.13.: Durchschnitt und Streuung bei verschiedenen zeitlichen Aggregationsebenen




Abbildung 5.14.: Veränderung Kennzahlen auf verschiedenen zeitlichen Aggregationsebenen bei *BUILD*-Datensatz




Abbildung 5.15.: Veränderung Kennzahlen auf verschiedenen zeitlichen Aggregationsebenen bei *CHEM*-Datensatz

Die durchschnittliche Standardabweichung wächst in beiden Beispielen an. Im Fall des *BUILD*-Beispiels steigt sie um den Faktor $\sim 3,71$, während sie im *CHEM*-Beispiel um den Faktor $\sim 2,64$ zunimmt. Interessant ist allerdings bei diesem Vergleich die Veränderung der Variationskoeffizienten, die die relative Streuung messen. Da mit einem Wechsel der zeitlichen Aggregationsebene auch die durchschnittliche Bestellmenge zunimmt, ist der Variationskoeffizient an dieser Stelle aussagekräftiger als die Standardabweichung. Der durchschnittliche Variationskoeffizient fällt in beiden Beispielen. Beim *BUILD*-Beispiel sinkt er um ungefähr 40% von 3,6 auf 2,2. Auf Monatsbasis beträgt der durchschnittliche Variationskoeffizient nur noch 60% von dem auf Wochenbasis. Beim *CHEM*-Beispiel sinkt der durchschnittliche Variationskoeffizient bei einem Übergang von Tages- auf Wochenbasis sogar um über 50% von 4,8 auf 2,3.

In diesen Beispielen sinkt der durchschnittliche Variationskoeffizient und somit die relative Streuung bei der Betrachtung längerer Zeiträume. Bereits Fliedner (1999) hat den Einfluss unterschiedlicher Aggregationsebenen auf die Streuung experimentell untersucht. Seine Ergebnisse bestätigen den hier beim *BUILD*- und *CHEM*-Datensatz beobachteten Effekt einer niedrigeren relativen Streuung bei der Verwendung längerer Zeiträume. Dieser Einfluss der zeitlichen Dimension auf die Streuung sollte von einer Supply Chain berücksichtigt werden, wenn sie die Länge der betrachteten Zeiträume für eine Planungsaufgabe bestimmt. Um eine hohe Streuung der betrachteten ADI und die damit verbundenen Unsicherheiten zu vermeiden, sollte eine Supply Chain bei der Auswahl der zeitlichen Aggregationsebene auf unnötige Details verzichten.²¹

²¹In den Ausführungen in den verbleibenden Abschnitten des Kapitels 5 werden die Daten aus dem *BUILD*-Datensatz wieder ausschließlich auf Wochen- und aus dem *CHEM*-Datensatz wieder ausschließlich auf Tagesbasis betrachtet.

5.4.3. Kennzahlen zur Korrelation

Wie in Abschnitt 5.1.4 bereits beschrieben, sind Kennzahlen zur Korrelation besonders beim ADI-Einsatz für die Nachfrageprognose durch lineare Regression interessant. Umso höher der Korrelationskoeffizient dabei ist, desto geeigneter erscheint der Einsatz der ADI für diese Form der Prognose.

Die Kennzahlen zur Korrelation wurden unter Einsatz der Fisher-z-Transformation, wie in Abschnitt 5.1.4 beschrieben, errechnet. Sie sind in Tabelle 5.20 aufgeführt. Im Fall des synthetischen *KEKRE*-Datensatzes ist die höchste durchschnittliche vorlaufzeitübergreifende Korrelation zwischen kumuliert vorliegender Bestellmenge und tatsächlicher Nachfrage mit $K_{4,Avg}(t_1, t_n, D_{Aes}) = 0,68$ zu beobachten. Der synthetische *KEKRE*-Datensatz ist also vorlaufzeitübergreifend am besten für die beschriebene Prognose geeignet. Der Wert liegt bei den Praxisdatensätzen zwischen 0,30 und 0,51, wobei *CHEM* mit $K_{4,Avg}(t_1, t_n, D_{Aes}) = 0,30$ die durchschnittlich schwächste Korrelation aufweist. Entsprechend ist der ADI-Einsatz hier am meisten durch die Supply Chain zu hinterfragen.

	$K_{4,Avg}(t_1, t_n, D_{Aes})$	$K_{4,Trend}(t_1, t_n, D_{Aes})$
<i>FIRE</i>	0,51	0
<i>BUILD</i>	0,43	-0,16
<i>CHEM</i>	0,30	-0,12
<i>KEKRE</i>	0,68	-0,27

Tabelle 5.20.: Korrelationskennzahlen der Datensätze

Mit der Kennzahl $K_{4,Trend}(t_1, t_n, D_{Aes})$ werden Unterschiede in der Korrelationsstärke für verschiedene Vorlaufzeiten identifiziert. Analog zu den Kennzahlen zur Form der Streuung beschreiben sie einen eventuell vorhandenen Trend in den Korrelationskoeffizienten. Fast einheitlich ist der zu beobachtende Trend bei den Beispieldatensätzen: In 3 von 4 Fällen ist dieser negativ, und bei *FIRE* ist er 0. Der negative Trend impliziert, dass mit zunehmender Vorlaufzeit die Korrelation zwischen kumuliert vorliegender Bestellmenge und tatsächlicher Nachfrage abnimmt. Am stärksten ist dieser Trend im synthetischen *KEKRE*-Beispiel mit $K_{4,Trend}(t_1, t_n, D_{Aes}) = -0,27$.²² Für die Supply Chains bedeutet dies, dass die Korrelationsstärke hoch und damit die Eignung der Prognosemethoden besonders bei den kurzfristigen Vorlaufzeiten gegeben ist.

Tabelle 5.21 zeigt die Kennzahlen zur Korrelation für ein dynamisches Bestellverhalten. Einzig bei *BUILD* und *CHEM* lassen die Kennzahlen auf Veränderungen rückschließen. Im Fall von *BUILD* deutet $K_{4,Dev,Avg}(t_1, t_n, D_{Aes}, p) = 0,059$ auf eine Steigerung der durchschnittlichen Korrelation im ex-post betrachteten Zeitraum. Gleichzeitig kann aus $K_{4,Dev,Trend}(t_1, t_n, D_{Aes}, p) = -0,073$ geschlossen werden, dass die Kennzahl $K_{4,Trend}(t_1, t_n, D_{Aes})$ zur Form der Korrelation abgenommen hat und die Unterschiede in der Korrelation zwischen lang- und kurzfristigen Vorlaufzeiten zurückgegangen sind. Die umgekehrte Situation liegt bei *CHEM* vor. Diese Veränderung der Korrelationsstärke

²² Auch die Trendsteigung bezieht sich auf die Fisher-z-transformierten Werte.

	p	$K_{4,Dev,Avg}(t_1, t_n, D_{Aes}, p)$	$K_{4,Dev,Trend}(t_1, t_n, D_{Aes}, p)$
<i>FIRE</i>	6	0	0
<i>BUILD</i>	6	0,059	-0,073
<i>CHEM</i>	10	-0,014	0,046
<i>KEKRE</i>	3	0	0

Tabelle 5.21.: Kennzahlen zur Korrelation für ein dynamisches Bestellverhalten

kann die Supply Chain bei der Entscheidung über die beschriebenen Prognosemethoden einfließen lassen.

5.4.4. Kennzahlen zur Konstanz der Zeitreihen

Tabelle 5.22 enthält die verbleibenden Kennzahlen zur Konstanz der Zeitreihen. Überprüft wurde mit dem Student-t-Test, ob bei einem Signifikanzniveau von 10% die Zeitreihen einem Trend unterliegen. Zusätzlich wurde untersucht, ob die Zeitreihen sporadisch sind. Dabei wurde eine Zeitreihe als sporadisch eingestuft, wenn mindestens die Hälfte der Werte 0 ist.

Wie bereits in Abschnitt 5.3 beschrieben, haben diese Kennzahlen vor allem eine Kon-

	<i>FIRE</i>	<i>BUILD</i>	<i>CHEM</i>	<i>KEKRE</i>
$K_{5,konst}(t_1, t_n, D_{Aes})$	0	42,9%	0	100%
$K_{5,konst}(t_1, t_n, U_{Aes})$	16,7%	92,3%	0	100%
$K_{5,konst}(t_1, t_n, X_{Aes})$	0	23,1%	18,2%	85,7%

Tabelle 5.22.: Kennzahlen zur Konstanz der Zeitreihen in den Datensätzen

trollfunktion. Sie messen den Anteil an Vorlaufzeiten innerhalb der Spannweite zwischen e_{start} bzw. e_{end} , denen eine Zeitreihe zwischen t_1 und t_n zugrunde liegt, die bis auf zufällige identisch unabhängig verteilte Abweichungen konstant ist. Je höher dieser Wert ist, umso größer ist der Anteil an Vorlaufzeiten, für die die in Kapitel 3 zur Definition des Auftragsprofils beschriebenen Durchschnitts- und Streuungswerte zur Erfassung des Bestellverhaltens geeignet sind.

In den Praxisdatensätzen hat der *BUILD*-Datensatz mit Werten zwischen 23,1% und 92,3% den höchsten Anteil an Vorlaufzeiten, für die eine Konstanz bei der zugrunde liegenden Zeitreihe nicht ausgeschlossen werden kann. Bei *FIRE* und *CHEM* kann für einen Großteil der Zeitreihen nachgewiesen werden, dass keine Konstanz vorliegt. Die entsprechenden Supply Chains müssen den Einsatz anderer Modelle aus der Zeitreihenanalyse erwägen, um eventuelle Systematiken in den Zeitreihen aufzudecken.

Der synthetische Datensatz von *KEKRE* zeichnet sich hier durch einen deutlich größeren Anteil aus. Abgesehen von den Werten zur anteilig vorliegenden Bestellmenge, bei denen der Anteil 85,7% beträgt, konnte bei keiner der verbleibenden Zeitreihen nachgewiesen werden, dass keine Konstanz vorliegt. Ein möglicher Grund für diesen hohen Anteil kann

der Hintergrund für die Erzeugung dieser Daten sein. Sie wurden als Anwendungsbeispiel auf eine neue ADI-basierte Prognosemethode zugeschnitten, um mit dieser möglichst gute Vorhersagen zu erzeugen. Diese Methode verwendet dabei ein Schätzverfahren, das sich besonders eignet, wenn die zugrunde liegende Zeitreihe konstant ist.

	<i>FIRE</i>	<i>BUILD</i>	<i>CHEM</i>	<i>KEKRE</i>
p	6	6	10	3
$K_{5,Dev,konst}(t_1, t_n, D_{\text{Aes}}, p)$	0	0	0	0
$K_{5,Dev,konst}(t_1, t_n, U_{\text{Aes}}, p)$	5,7%	-10,7%	0	0
$K_{5,Dev,konst}(t_1, t_n, X_{\text{Aes}}, p)$	6,7%	2,9%	0	0

Tabelle 5.23.: Kennzahlen zur Konstanz für ein dynamisches Bestellverhalten

Zusätzlich können die Supply Chains die Entwicklung des beschriebenen Anteils in die Entscheidung einfließen lassen. Dafür sind in Tabelle 5.23 die Kennzahlen zur Konstanz für ein dynamisches Bestellverhalten aufgeführt. Die Daten aus *CHEM* und *KEKRE* verändern sich gar nicht. Auch für viele der Praxisdatensätze ist keine Veränderung zu beobachten. Die dynamischen Kennzahlen für die kumuliert vorliegenden Bestellmengen sind alle 0. Der Anteil an konstanten Zeitreihen hat sich also im ex-post betrachteten Zeitraum nicht signifikant verändert. Eine Abnahme des Anteils ist einzig bei *BUILD* für die ausstehende Bestellmenge zu sehen. Sonst liegen die Trendsteigungen des Anteils zwischen 2,9% und 6,7%.

5.4.5. Zusammenfassung

Das beschriebene Kennzahlensystem ermöglicht die Charakterisierung des Bestellverhaltens in den aufgeführten Kategorien.

Der synthetische Datensatz von *KEKRE* unterscheidet sich dabei deutlich von den zur Verfügung stehenden Praxisdatensätzen. Er weist eine geringere durchschnittliche Streuung auf, hat eine stärkere durchschnittliche Korrelation zwischen kumuliert vorliegender Bestellmenge und tatsächlicher Nachfrage sowie einen höheren Anteil an Zeitreihen, für die eine Konstanz nicht auszuschließen ist. Der Datensatz ist deshalb nicht repräsentativ für das in den untersuchten Praxisdatensätzen beobachtete Bestellverhalten. Dieser Unterschied kann, wie bereits ausgeführt, dadurch begründet sein, dass der Datensatz als Anwendungsbeispiel speziell auf eine bestimmte ADI-basierte Prognosemethode zugeschnitten wurde.

Ein Vergleich der Praxisdatensätze ist schwierig. Zum einen wurden der Analyse verschiedene zeitliche Dimensionen (Tages-, Wochen- und Monatsbasis) zugrunde gelegt. Wie in Abschnitt 5.4.2 anhand der Praxisdatensätze gezeigt wurde, hat die verwendete zeitliche Dimension starken Einfluss auf die Streuung im Bestellverhalten. Zum anderen beziehen sich die Bestellmengen auf unterschiedliche nicht zu vereinheitlichende Maßeinheiten. Trotzdem können aus der individuellen Analyse der einzelnen Datensätze interessante Rückschlüsse auf das charakteristische Bestellverhalten gezogen werden, die für die Supply Chains bei den verschiedensten Entscheidungen relevant sind. In den Kapiteln 6 bis

8 wird dies exemplarisch für zwei Beispiele detailliert dargestellt.

5.5. Einsatzmöglichkeiten für Curve Fitting zur Charakterisierung des Bestellverhaltens

Das in den Abschnitten 5.1 bis 5.3 entwickelte Kennzahlensystem erlaubt eine umfassende Charakterisierung des Bestellverhaltens. Dafür sind allerdings insgesamt 40 Kennzahlen erforderlich.²³ Hier kann das in Kapitel 4 vorgestellte Curve Fitting für eine kompaktere Darstellung des Bestellverhaltens genutzt werden.




Abbildung 5.16.: An den Beispieldatensatz angepasste Normalverteilungsfunktion

Beim Curve Fitting werden die Parameter einer durch den Anwender zu spezifizierenden Funktion f abgestimmt, um den dahinterliegenden Datensatz möglichst genau zu repräsentieren bzw. die verbleibenden Abweichungen der einzelnen Datenpunkte von der Funktion zu minimieren. In Abbildung 5.16 ist ein solches Curve Fitting exemplarisch dargestellt. Im linken Graphen sind die anteilig vorliegenden Bestellmengen aus dem Beispiel aus Abbildung 3.5 graphisch abgebildet. Bei Betrachtung der Bestellungsentwicklung in diesem Beispiel erscheint die Verteilungsfunktion der Normalverteilung geeignet für die Abschätzung des Bestellverhaltens.²⁴ Gleiches gilt auch für die Datensätze aus Abbildung 5.8 im letzten Abschnitt. Unabhängige Variable ist in diesen Beispielen im-

²³ Je 20 Kennzahlen zu einem statischen und dynamischen Bestellverhalten. Dabei gibt es jeweils drei Kennzahlen zur Spannweite, sechs Kennzahlen zur durchschnittlichen Streuung, sechs Kennzahlen zur Form der Streuung, zwei Kennzahlen zur Korrelation zwischen vorliegender Bestellmenge und tatsächlicher Nachfrage und drei Kennzahlen zur Konstanz der zugrunde liegenden Zeitreihen.

²⁴ Alternativ wäre auch der Einsatz der negativen Binomialverteilung denkbar. Dies wird hier aber nicht weiter untersucht.

mer die Vorlaufzeit und abhängige Variable die anteilig vorliegende Bestellmenge. Da die anteilig vorliegende Bestellmenge allerdings typischerweise mit zunehmender Vorlaufzeit fällt und die Normalverteilung steigt, sollte die folgende angepasste Funktion verwendet werden: $f(\mathbf{x}|\mathbf{w} = (\mu, \sigma)) = 1 - \int_{-\infty}^x \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{-\frac{1}{2}\left(\frac{t-\mu}{\sigma}\right)^2} dt$. Die Parameter dieser Funktion sind der Erwartungswert μ und die Standardabweichung σ . In Abbildung 5.16 ist im rechten Graphen nun die angepasste Funktion eingebettet, die den MSE für das Beispiel minimiert. In diesem Beispiel gilt $\mu = 4,11$ und $\sigma = 1,52$.²⁵ Es sind so nur noch die Parameter μ und σ notwendig, um den durchschnittlichen Bestellungsverlauf zu beschreiben. Für die Datensätze aus Abschnitt 5.4 wurde obige adaptierte Verteilungsfunktion der Normalverteilung ebenfalls “gefittet”. Die resultierenden Funktionen sind in Abbildung 5.17 eingebettet. Tabelle 5.24 enthält die Parameterwerte μ und σ zu diesen Funktionen.

	<i>FIRE</i>	<i>BUILD</i>	<i>CHEM</i>	<i>KEKRE</i>
μ	3,30	2,41	1,65	3,98
σ	1,96	1,10	0,42	1,90

Tabelle 5.24.: Angepasste Parameter der Funktionen aus Abbildung 5.17

Die Qualität der angepassten Funktionen kann über die Höhe der verbleibenden Abweichungen bewertet werden. Der MSE kann als Maß für diese Abweichungen genutzt werden, wobei die Quadratwurzel des MSE der vorlaufzeitübergreifenden Standardabweichung der angepassten Funktion entspricht.²⁶ Zur Beurteilung der Qualität der angepassten Funktion muss nun die Quadratwurzel des MSE mit der Kennzahl zur vorlaufzeitübergreifenden durchschnittlichen Standardabweichung $K_{2,\sigma}(t_1, t_n, X_{\text{Aes}})$ aus Abschnitt 5.1.2 verglichen werden. Ist die Quadratwurzel des MSE signifikant größer als diese Kennzahl, so ist die angepasste Funktion nicht geeignet zur Beschreibung des Bestellverhaltens. Die tatsächliche Streuung ist in diesem Fall deutlich niedriger als die Quadratwurzel des MSE. Ist die Differenz aber nur gering, kann die Funktion verwendet werden. Tabelle 5.25 enthält die durchschnittliche Streuung für die Beispiele aus Abbildung 5.17.²⁷ Die absolute Erhöhung der durchschnittlichen Standardabweichung liegt dabei in allen vier Fällen deutlich unter 1%. Der Einsatz von Curve Fitting erscheint deshalb hier geeignet. Bei ausreichender Qualität der angepassten Funktion können nun aus deren Parame-

²⁵Diese Parameterwerte sowie alle folgenden Werte in diesem Abschnitt wurden manuell durch ein Tabellenkalkulationsprogramm berechnet. Die Optimalität dieser Parameter im Bezug auf die jeweils verwendete Funktion wurde durch eine umfassende Sensitivitätsanalyse der Werte überprüft. Wie bereits in Kapitel 4 erwähnt, können alternativ auch Computerprogramme wie Matlab, Mathematica, Origin oder R zur Berechnung der Werte eingesetzt werden.

²⁶Vgl. dazu u.a. Silver u.a. (1998, S. 111).

²⁷Die Werte zu $K_{2,\sigma}(t_1, t_n, X_{\text{Aes}})$ sind nicht einfach Tabelle 5.17 entnommen. Da bei der angepassten Funktion Streuung noch vor dem Anfangspunkt auftreten kann, müssen auch diese Vorlaufzeiten in der Kennzahl zur durchschnittlichen Streuung berücksichtigt werden. Die Streuung in der ursprünglichen Darstellung betrug für diese Vorlaufzeiten immer 0. Sie wurde bei der Berechnung der Durchschnittsstreuung übergangen und muss deshalb jetzt im Nachhinein hinzugerechnet werden. Die angepasste Funktion für den Datensatz *CHEM* ist durch einen hohen Anteil an Wunschlieferzeitpunkten begründet, bei denen für Vorlaufzeiten zwischen 3 und 5 Tagen die anteilig vorliegende Bestellmenge 0 beträgt.





Abbildung 5.17.: Angepasste Funktionen für Datensätze aus Abschnitt 5.4

	<i>FIRE</i>	<i>BUILD</i>	<i>CHEM</i>	<i>KEKRE</i>
Angepasste Kennzahl $K_{2,\sigma}(t_1, t_n, X_{Aes})$	16,0%	10,5%	15,6%	1,4%
MSE zur angepassten Funktion	16,2%	10,7%	16,2%	1,6%

Tabelle 5.25.: Vergleich der durchschnittlichen Streuung aus Abschnitt 5.1.2 und der Quadratwurzel des MSE zur angepassten Funktion

terwerten einige der in Abschnitt 5.1 vorgestellten Kennzahlen einfach abgeleitet werden. Wie bereits beschrieben, kann der MSE zur Abschätzung der durchschnittlichen Standardabweichung $K_{2,\sigma}(t_1, t_n, X_{Aes})$ benutzt werden. Die Kennzahlen zur Spannweite können ebenfalls leicht auf Basis der angepassten Funktion bestimmt werden. Anfangs- bzw. Endpunkt markieren einfach die Vorlaufzeit, zu der die Funktion einen bestimmten Wert unter- bzw. überschreitet. In Abbildung 5.18 ist dies für den Praxisdatensatz *FI-RE* beispielhaft illustriert. Der Anfangspunkt entspricht dem 90%-Quantil, das bei der angepassten Funktion bei $e = 0,79$ liegt. Für den Endpunkt wurde entsprechend das 10%-Quantil gewählt, das den Wert $e = 5,81$ hat. Die resultierende Spannweite beträgt 5,02.


Curve Fitting kann auch für die kumuliert vorliegende und ausstehende Bestellmenge verwendet werden. Da diese allerdings absolute Bestellmengen enthalten, kann die Ver-

Abbildung 5.18.: Beispielfhafte Bestimmung der Spannweite für *FIRE*

teilungsfunktion der Normalverteilung in der verwendeten Variante hier nicht benutzt werden. Die folgende angepasste Version ist für die kumuliert vorliegende Bestellmenge allerdings denkbar: $f(\mathbf{x}|\mathbf{w} = (a, \mu, \sigma)) = a \cdot \left(1 - \int_{-\infty}^x \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{-\frac{1}{2}\left(\frac{t-\mu}{\sigma}\right)^2} dt\right)$. Der dritte Parameter a soll in dieser Variante die Funktion entsprechend der kumuliert vorliegenden Bestellmengen skalieren. Genauso wie sich die Verteilungsfunktion beim Curve Fitting der kumuliert vorliegenden Bestellmenge eignet, ist folgende Dichtefunktion für die einfache Bestellmenge d_{Aes} passend: $f(\mathbf{x}|\mathbf{w} = (a, \mu, \sigma)) = a \cdot \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$. Für das *KEKRE*-Beispiel sind die beiden jeweils angepassten Funktionen inklusive der drei Parameterwerte in Abbildung 5.19 aufgeführt. Es wurden dabei getrennte Fittings für die beiden Funktionen durchgeführt, um diese möglichst individuell und genau an den zugrunde liegenden Datensatz anzupassen, weshalb sich die resultierenden Parameterwerte auch unterscheiden.

Die Parameterwerte aus dem Curve Fitting ermöglichen eine kompaktere Charakterisierung des Bestellverhaltens als dies durch die Kennzahlen aus den Abschnitten 5.1 bis 5.3 möglich ist. Besonders die Parameterwerte μ und σ im Zusammenhang mit dem dazugehörigen MSE erlauben eine knappe Charakterisierung des Bestellverhaltens. So erlauben beispielsweise bei der anteilig vorliegenden Bestellmenge die Parameterwerte zur angepassten Normalverteilungsfunktion folgende Charakterisierung:

- μ Die Kennzahl repräsentiert die durchschnittliche Vorlaufzeit, mit der auf der betrachteten Aggregationsebene Bestellungen getätigt wurden. Wie Tabelle 5.24 zu entnehmen ist, gingen beispielsweise bei *KEKRE* Bestellungen durchschnittlich mit einer Vorlaufzeit von 3,98 ein. Gleichzeitig lag zu dieser Vorlaufzeit im Schnitt die Hälfte der tatsächlichen Nachfrage vor.
- σ Diese Kennzahl markiert die Unterschiede in den Vorlaufzeiten, zu denen bestimmte Anteile der Bestellmenge durchschnittlich vorlagen. Je größer die

Abbildung 5.19.: Curve Fitting beim *KEKRE*-Beispiel für die kumuliert und einfach vorliegende Bestellmenge

	Vorlaufzeit:	μ	$\mu - \sigma$	$\mu - 2\sigma$
	Vorlaufzeit im <i>KEKRE</i> -Beispiel:	3,98	2,08	0,18
	Durchschnittlich anteilig vorliegende Bestellmenge:	50,00%	84,13%	97,72%

Tabelle 5.26.: Anteilig vorliegende Bestellmengen zu unterschiedlichen Vorlaufzeiten

Streuung ist, desto mehr war der Bestellungseingang in die Länge gezogen. Mit den verbreiteten Tabellen zur Standardnormalverteilung²⁸ können Vorlaufzeiten, zu denen bestimmte Anteile der Bestellmenge im Schnitt vorlagen, einfach abgeschätzt werden. Tabelle 5.26 sind beispielhaft einige Werte für das *KEKRE*-Beispiel zu entnehmen, bei dem die Streuung 1,90 beträgt.

MSE Der MSE gibt die durchschnittliche Varianz des Bestellverhaltens um die durch μ und σ beschriebene Normalverteilungsfunktion an. Die Quadratwurzel des MSE gibt ähnlich wie die Kennzahl $K_{2,\sigma}(t_1, t_n, X_{\text{Acs}})$ aus Abschnitt 5.1.2 die Durchschnittsstreuung an. Wie Tabelle 5.25 zu entnehmen ist, ist in obigem *KEKRE*-Beispiel die Durchschnittsstreuung 1,6%.

Der Vorteil dieser Kennzahlen ist, dass sie als Resultat des Curve Fitting bereits vorliegen. Sie geben gleichzeitig, wie beschrieben, einen ersten Eindruck des Bestellverhaltens und erlauben so eine erste schnelle Einschätzung desselben. Für eine anschließende Detailanalyse und die damit verbundenen Rückschlüsse können und sollten weiterhin die Kennzahlen aus den Abschnitten 5.1 bis 5.3 verwendet werden.

²⁸Vgl. beispielsweise Pearson und Hartley (1976a, S. 110–116) oder Pearson und Hartley (1976b, S. 153–155).

5.6. Zusammenfassung

In diesem Kapitel wurden unterschiedliche Kennzahlen zur Charakterisierung des Bestellverhaltens vorgestellt. Dabei wurden die unterschiedlichsten Aspekte des Bestellverhaltens beleuchtet, die für eine Supply Chain bei der Entscheidung wichtig sind, ob sie die ADI für eine Planungsaufgabe verwenden möchte.

Verwendet die Supply Chain Curve Fitting-Methoden zur Charakterisierung des Bestellverhaltens, wie in Abschnitt 5.5 beschrieben, so stehen ihr dadurch bereits drei wichtige Kennzahlen zur Bewertung des Bestellverhaltens zur Verfügung. Die beiden Parameterwerte einer angepassten Normalverteilungsfunktion dienen als Kennzahl für die durchschnittliche Vorlaufzeit, mit der Bestellungen eingehen, und die Streuung dieser Vorlaufzeiten. Zusätzlich kann durch den dazugehörigen MSE vorlaufzeitübergreifend die durchschnittliche Streuung des Bestellverhaltens abgeschätzt werden.

Für eine detaillierte Analyse des Bestellverhaltens wurde das in den Abschnitten 5.1 bis 5.3 vorgestellte Kennzahlensystem entwickelt. Je nach Planungsaufgabe, für die eine Supply Chain die ADI verwenden möchte, können verschiedene Kennzahlen berechnet werden, die die relevanten Aspekte analysieren. Die Kennzahlen sind dabei in folgende Kategorien unterteilt:

- Spannweite
- Streuung (Durchschnitt und Form)
- Korrelation und
- Konstanz der Bestellmengen

Dabei werden neben dem statischen Bestellverhalten auch Entwicklungen in dem ex-post betrachteten Zeitraum durch verschiedene dynamische Kennzahlen beschrieben. Die Supply Chain bekommt so die Möglichkeit, auf bereits aufgetretene und in den vorliegenden Bestelldaten enthaltene Entwicklungen adäquat zu reagieren. Der Einsatz und die Relevanz des Kennzahlensystems wurden auf Basis von drei Praxisdatensätzen und eines synthetischen Datensatzes in Abschnitt 5.4 demonstriert. Der Einfluss der zeitlichen Dimension auf das Bestellverhalten wurde dabei empirisch untersucht. Bei der Betrachtung längerer Zeiträume kann die Streuung im Bestellverhalten sinken. Diesen Umstand sollten die Supply Chains bei der Ausgestaltung ihrer Planungsaufgaben berücksichtigen und einen unnötig hohen Detailgrad vermeiden.

Das Kennzahlensystem wurde entwickelt, um die Einsetzbarkeit der ADI für unterschiedliche Planungsaufgaben einer Supply Chain einzuschätzen. Wie zu Beginn dargestellt, kann die ADI für die unterschiedlichsten Planungsaufgaben genutzt werden. In den folgenden Kapiteln wird die Relevanz der Kennzahlen für zwei Aufgaben exemplarisch dargestellt:

1. Die Bestimmung der Entkopplungspunktposition
2. Die Eignung ADI-basierter Prognosemethoden zur Vorhersage der zukünftigen Nachfrage

5. Charakterisierung des Bestellverhaltens

Dabei sind für die unterschiedlichen Planungsaufgaben verschiedene Kennzahlen ausschlaggebend. Das Kennzahlensystem bildet die Grundlage für die Analyse des Bestellverhaltens. Es untersucht allgemein wichtige Aspekte der Verwendbarkeit der ADI. Sind für den Einsatz der ADI weitere Aspekte relevant, kann das Kennzahlensystem natürlich entsprechend flexibel erweitert werden.

6. Einfluss des Bestellverhaltens auf den Entkopplungspunkt

Wie bereits in Kapitel 2 beschrieben, wird in dieser Arbeit erstmals eine Methode vorgestellt, die es erlaubt, den Entkopplungspunkt ex-post zu messen. Das entwickelte Verfahren erklärt detailliert den Einfluss, den das Bestellverhalten der Kunden auf die Entkopplungspunktposition ausübt. Der sukzessive Bestellungseingang wird dabei explizit berücksichtigt. Die Verwendbarkeit der ADI als Grundlage für die kurz- bis mittelfristige Planung von Wertschöpfungsschritten wird dadurch ersichtlich. Dies ermöglicht eine bessere Abstimmung und Integration der ADI in die operativen Planungsaufgaben einer Supply Chain.

Gleichzeitig ist die Methode wichtig für eine Repositionierung des Entkopplungspunkts im Rahmen des Strategic Network Designs. Die Methode erlaubt es, die tatsächliche mit der zuvor geplanten Entkopplungspunktposition zu vergleichen und ist eine wichtige Grundlage für die Identifikation von Schwachstellen und die Erarbeitung von Optimierungsansätzen. Die Analyseergebnisse dieses Kapitels sind deshalb sowohl für operative Planungsaufgaben als auch für strategische Überlegungen im Strategic Network Design sehr bedeutsam.

Als Basis für die quantitative Analyse wird in Abschnitt 6.1 zunächst die Ausgangslage detailliert erläutert, und wichtige Begriffe werden eindeutig abgegrenzt. Außerdem wird der Einfluss der ADI auf den Entkopplungspunkt konzeptionell dargestellt. Zur Bestimmung der Entkopplungspunktposition müssen zusätzlich noch verschiedene Durchlauf- und Lieferzeiten erfasst werden. Diese Messwerte sowie eine Vorgehensweise für deren Erhebung werden in Abschnitt 6.2 vorgestellt. Das eigentliche Verfahren zur ex-post Bestimmung der Entkopplungspunktposition wird in Abschnitt 6.3 beschrieben. Die Durchführung sämtlicher Verfahrensschritte wird an einem fiktiven Beispiel aus der Porzellanherstellung demonstriert, um die Zusammenhänge für den Leser zu verdeutlichen.

6.1. Ausgangslage und Bedeutung von ADI für den Entkopplungspunkt

Wie bereits in Kapitel 2 erläutert, ist der Entkopplungspunkt in der Literatur häufig als späteste Stelle in der Wertschöpfungskette einer Supply Chain definiert, nach der sämtliche Schritte nur noch ausgeführt werden, wenn dafür ein konkreter Kundenauftrag vorliegt. Die Wertschöpfungsschritte vor dem Entkopplungspunkt werden auf Grundlage von Nachfrageprognosen geplant und gesteuert. In dieser klassischen Definition ist

der Entkopplungspunkt als eindeutige Stelle in der Wertschöpfungskette definiert. Jeder Wertschöpfungsschritt liegt entweder vor oder hinter dem Entkopplungspunkt und wird entweder auf Basis von Nachfrageprognosen oder Aufträgen geplant. Die Zeitdauer vom Beginn der Wertschöpfungskette bis zum Entkopplungspunkt wurde von Meyr (2003), wie bereits in Kapitel 2 erläutert, als Wiederbeschaffungszeit und die Zeitdauer vom Entkopplungspunkt bis zum Abschluss der Wertschöpfungskette als Lieferzeit definiert.¹ Als Durchlaufzeit wird die Zeitdauer bezeichnet, die für die Durchführung eines Wertschöpfungsschritts benötigt wird.

Für das Verfahren wird eine beliebige Wertschöpfungskette betrachtet, wie sie von Porter (2014, S. 61–85) definiert und in Kapitel 2 erklärt wurde. Die Untersuchung ist dabei auf einen kritischen Pfad innerhalb dieser Wertschöpfungskette fokussiert. Domschke und Scholl (1999, S. 121) sowie Schneck (2007, S. 665) beschreiben einen kritischen Pfad als eine Abfolge von Schritten ohne zeitlichen Puffer. Die Durchlaufzeit für die Durchführung des gesamten kritischen Pfads entspricht der Summe der Durchlaufzeiten aller einzelnen Schritte auf dem Pfad. Verlängert sich die Durchlaufzeit eines Schritts auf dem kritischen Pfad oder kommt es zu einer Pause zwischen zwei Schritten, steigt auch die Durchlaufzeit für die Durchführung des gesamten Pfads entsprechend. In Abbildung 6.1 ist ein solcher kritischer Pfad bestehend aus p Schritten illustrativ dargestellt.



Abbildung 6.1.: Kritischer Pfad in einer Wertschöpfungskette

Dieser Fokus auf den kritischen Pfad wurde für das Verfahren bewusst gewählt. Durch das Fehlen eines zeitlichen Puffers zwischen den einzelnen Schritten hat die Durchlaufzeit eines jeden einzelnen Schritts, der downstream von einem beliebigen Entkopplungspunkt liegt, direkten Einfluss auf die resultierende Lieferzeit. Steigt die Durchlaufzeit eines solchen Schritts, dann verlängert sich auch die Lieferzeit. Die Summe der Durchlaufzeiten aller Schritte vor dem Entkopplungspunkt ergibt die Wiederbeschaffungszeit auf dem kritischen Pfad, weil keine Puffer zwischen den Schritten zu berücksichtigen sind. Analog ergibt die Summe der Durchlaufzeiten aller Schritte nach dem Entkopplungspunkt die Lieferzeit. Für Schritte außerhalb des kritischen Pfads ist dies nicht notwendigerweise genauso. Eine Verlängerung der Durchlaufzeit kann hier gegebenenfalls durch die zeitlichen Puffer zwischen den Schritten ausgeglichen werden, so dass die Lieferzeit unverändert bleibt. Der Anwender des vorgestellten Verfahrens sollte allerdings beachten, dass sich kritische Pfade innerhalb einer Wertschöpfungskette verändern können.

Wie angekündigt wird ein Beispiel aus der Porzellanherstellung benutzt, um das Verfahren demonstrativ vorzuführen. Der kritische Pfad des betrachteten Porzellanherstellers besteht aus sechs Wertschöpfungsschritten, die in Abbildung 6.2 dargestellt sind.

¹Es ist zu beachten, dass sowohl für den Auftragseingang, die -übermittlung als auch die -verarbeitung eine gewisse Zeitdauer benötigt werden kann. Der Einfluss dieser Zeitdauer wird an späterer Stelle noch erklärt.



Abbildung 6.2.: Kritischer Pfad in der Wertschöpfungskette am Beispiel eines Porzellanherstellers

Die Wertschöpfung beginnt mit dem Einkauf der notwendigen Rohstoffe wie Feldspat, Kaolin und verschiedenen Quarzen für die Porzellanproduktion. Im zweiten Schritt werden diese Rohstoffe vermischt und zu einem Rohling geformt. Der Hersteller in diesem Beispiel verkauft Teller, Tassen und Schüsseln. Der Rohling nimmt entsprechend eine dieser drei Formen an. Er wird zum Abschluss dieses Schritts einem ersten Brennvorgang unterzogen. Im dritten Schritt wird auf das Produkt eine Glasur aufgetragen und anschließend ein zweiter Brennvorgang durchgeführt. Das Porzellan wird in fünf unterschiedlichen Farbvarianten (Blau, Rot, Grün, Schwarz oder Gelb) angeboten. Das Porzellan wird im vierten Schritt passend eingefärbt und einem letzten Brennvorgang unterzogen. Im fünften Schritt erfolgt die Bemalung des Porzellans mit einer individuellen und kunden-spezifischen Beschriftung. Dies kann beispielsweise das Firmenlogo des Kunden sein, das auf eine Tasse aufgetragen wird. Die Wertschöpfung wird mit der Auslieferung der Ware abgeschlossen. Dieses Beispiel wird im weiteren Verlauf des Kapitels aufgegriffen, um die wichtigsten Verfahrensschritte zu demonstrieren.

Bedeutung der ADI für den Entkopplungspunkt

Der Einfluss des Bestellverhaltens auf die Planung und Steuerung einer Wertschöpfungskette und damit auf den Entkopplungspunkt steht im Mittelpunkt dieses Kapitels. Dabei ist hervorzuheben, dass Bestellungen in der Praxis typischerweise mit unterschiedlichen Vorlaufzeiten eingehen. Die in Kapitel 5 untersuchten Praxisdatensätze zeigen diesen sukzessiven Bestellungseingang ganz deutlich. In Abbildung 5.8 ist zu erkennen, wie die Bestellungen im Beispiel *FIRE* mit Vorlaufzeiten zwischen 0 und 6 Monaten eingegangen sind. Bei *BUILD* variiert die Vorlaufzeit der Bestellungen zwischen 0 und 13 Wochen und bei *CHEM* zwischen 0 und 35 Tagen. Auch die Ergebnisse der Untersuchungen von Vollmann u.a. (1992, S. 317 ff.) und Vollmann u.a. (2005, S. 17 ff.), die in Kapitel 2 in Abbildung 2.13 dargestellt sind, zeigen diesen sukzessiven Bestellungseingang.

Wie von Meyr (2003) kritisiert und bereits in Kapitel 2 erläutert, wird dieser sukzessive Bestellungseingang durch das klassische Entkopplungspunktkonzept nicht berücksichtigt. Dem Konzept liegt die Annahme zugrunde, dass der Entkopplungspunkt eine fixe Stelle in der Wertschöpfungskette markiert. Jeder Wertschöpfungsschritt liegt entsprechend eindeutig up- oder downstream dieses Punkts und wird entweder prognose- oder auftragsbasiert gesteuert und geplant. Wie von Meyr (2003) gezeigt, impliziert dies, dass alle Bestellungen mit der gleichen Vorlaufzeit eingehen. Diese Vorlaufzeit entspricht der Durchlaufzeit für die Durchführung aller Schritte downstream des Entkopplungspunkts. Kürzere Vorlaufzeiten sind bei den Bestellungen nicht möglich, weil per Definition für alle Schritte nach dem Entkopplungspunkt sämtliche Aufträge vorliegen. Längere Vorlaufzei-

ten sind nicht möglich, weil sonst bereits Bestellungen für die Planung der Aktivitäten upstream des Entkopplungspunkts bereitstanden, die allerdings rein prognosebasiert geplant wurden. Analog zu Meyr (2003) ist das damit verbundene Bestellverhalten in Abbildung 2.11 in Kapitel 2 illustriert. Zu Vorlaufzeiten, die die Lieferzeit des Entkopplungspunkts überschreiten, sind 0% und bei kürzeren Vorlaufzeiten 100% der Bestellmenge bekannt. Ein solches Bestellverhalten ist in der Realität nicht zu beobachten, wie die untersuchten Praxisdatensätze in Kapitel 5 exemplarisch gezeigt haben.

Der tatsächliche Zusammenhang zwischen dem Bestellverhalten und dem Entkopplungspunkt sowie den unterschiedlichen Planungsgrundlagen für die Wertschöpfungsschritte ist in Abbildung 6.3 dargestellt. Wie bereits von Meyr (2003) erkannt, sind drei Situationen bei der Planung eines Wertschöpfungsschritts zu unterscheiden:

1. Eine rein auftragsbasierte Planung
2. Eine Mischform aus auftrags- und prognosebasierter Planung
3. Eine rein prognosebasierte Planung

Die erste und die dritte Situation sind bereits aus dem klassischen Entkopplungspunktkonzept bekannt. Eine rein auftragsbasierte Planung wird durchgeführt, wenn 100% der Bestellmenge bekannt sind. In Abbildung 6.3 ist ein solcher Wertschöpfungsschritt weiß markiert. Rein prognosebasiert wird geplant, wenn noch keine Bestellungen vorliegen. Der schwarze Wertschöpfungsschritt in Abbildung 6.3 wird so geplant. Da die Bestellungen allerdings sukzessiv eingehen, gibt es auch Wertschöpfungsschritte, bei denen zum Planungszeitpunkt bereits einige Aufträge bekannt sind, aber noch nicht alle Bestellungen aufgegeben wurden. In einer solchen Situation können die vorliegenden Aufträge natürlich für die Planung benutzt werden, müssen allerdings mit einer Prognose für die noch ausstehende Bestellmenge kombiniert werden. Der graue Wertschöpfungsschritt in Abbildung 6.3 kann auf Grundlage dieser Kombination aus Aufträgen und Prognosen geplant werden.

Der Entkopplungspunkt ist entsprechend keine eindeutige Stelle in der Wertschöpfungskette, die auftrags- und prognosebasierte Planung trennt. Es sind vielmehr drei verschiedene Grundlagen für die Planung eines Wertschöpfungsschritts zu unterscheiden. Die Zuordnung der Wertschöpfungsschritte zu diesen drei unterschiedlichen Situationen ist zur Bestimmung des Entkopplungspunkts und Abgrenzung der verschiedenen Planungsgrundlagen notwendig.

Das Vorgehen zur ex-post Identifikation dieser drei Situationen basiert auf dem Abgleich der Durchlauf- und Lieferzeiten der Wertschöpfungskette mit den Vorlaufzeiten, die für die Bestellungen beobachtet wurden. Wie bereits in Kapitel 2 erläutert, sind nach Gollwitzer und Karl (1998, S. 68–71) drei Lieferzeitpunkte zu unterscheiden:

1. Der Wunschlieferzeitpunkt
2. Der dem Kunden versprochene Lieferzeitpunkt
3. Der tatsächliche Lieferzeitpunkt




Abbildung 6.3.: Einfluss der ADI auf den Entkopplungspunkt

Der dem Kunden versprochene Lieferzeitpunkt wird im Rahmen des Order Promisings von der Supply Chain ermittelt. Die Zeit zwischen dem Bestellungseingang und diesem versprochenen Lieferzeitpunkt entspricht der Soll-Lieferzeit für diesen Auftrag aus Sicht der Supply Chain. Die Supply Chain verspricht dem Kunden die Ware zu diesem Zeitpunkt auszuliefern und begrenzt damit gleichzeitig die Zeit, die ihr für die pünktliche Auslieferung und das Halten dieses Versprechens noch zu Verfügung steht. Die tatsächliche Lieferzeit, die den Zeitrahmen zwischen Bestellungseingang und tatsächlichem Lieferzeitpunkt beschreibt, darf diese Soll-Lieferzeit nicht überschreiten, wenn der Auftrag spätestens zum versprochenen Lieferzeitpunkt ausgeliefert werden soll.

Wie bereits in Kapitel 2 ausgeführt, ist es für den langfristigen Erfolg einer Supply Chain entscheidend, dass sie die Kundenerwartungen an den Lieferzeitpunkt erfüllt. Der Wunschlieferzeitpunkt gibt die Kundenerwartungen bezüglich des Lieferzeitpunkts vor. Die Zeit zwischen dem Bestellungseingang und Wunschlieferzeitpunkt entspricht deshalb der Soll-Lieferzeit für diesen Auftrag aus Kundensicht. Überschreitet die tatsächliche Lieferzeit diese Soll-Lieferzeit werden die bestellten Waren erst nach dem Wunschlieferzeitpunkt ausgeliefert. Da eine Supply Chain dies nicht regelmäßig tun darf, um erfolgreich am Markt zu bestehen, begrenzt diese Soll-Lieferzeit aus Kundensicht und der damit verbundene Wunschlieferzeitpunkt die Zeit, die zur Fertigstellung und Auslieferung der Waren zur Verfügung steht. Sie ist damit maßgeblich für die Position des Entkopplungspunkts.

Die tatsächliche Lieferzeit entspricht gleichzeitig der Summe der Durchlaufzeiten für al-

le Wertschöpfungsschritte auf dem kritischen Pfad bis zu dessen Abschluss, die nach dem Bestellungseingang noch geplant und durchgeführt werden müssen. Diese Summe der Durchlaufzeiten wird hier als verbleibende Durchlaufzeit definiert. Die verbleibende Durchlaufzeit ist exemplarisch für die letzten drei und vier Wertschöpfungsschritte in Abbildung 6.4 dargestellt.²




Abbildung 6.4.: Verbleibende Durchlaufzeit auf kritischem Pfad einer Wertschöpfungskette

Damit ein bestimmter Auftrag für die Planung eines Wertschöpfungsschritts genutzt werden konnte, darf die verbleibende Durchlaufzeit dieses Schritts die Soll-Lieferzeit der Bestellung nicht übersteigen. Wenn die verbleibende Durchlaufzeit eines Schritts nämlich länger als diese Soll-Lieferzeit aus Kundensicht war, dann musste mit der Planung dieses Schritts bereits vor dem Bestellungseingang begonnen werden, um den Auftrag zum Wunschlieferzeitpunkt abzuschließen. In Abbildung 6.4 liegt eine solche Situation beim viertletzten Wertschöpfungsschritt vor. Dieser Schritt musste bereits vor dem Bestellungseingang begonnen werden, damit eine Auslieferung zum Wunschlieferzeitpunkt gewährleistet werden konnte. Für die drei letzten Wertschöpfungsschritte genügte es hingegen, mit der Planung und Ausführung erst nach dem Bestellungseingang anzufangen, ohne die Auslieferung zum Wunschlieferzeitpunkt, wie in Abbildung 6.4 dargestellt, zu gefährden. Der Auftrag konnte hier entsprechend für die Planung der Schritte benutzt werden. Auf diese Weise kann ex-post geklärt werden, welche der drei aufgeführten Situationen für die Planung eines Wertschöpfungsschritts vorlag und welche Bestellungen für die Planung bereits zur Verfügung standen.

Um den Entkopplungspunkt auf dem kritischen Pfad einer Wertschöpfungskette zu bestimmen, müssen nun die Durchlauf- und Lieferzeiten, die mit den verschiedenen Wert-

²Es ist hervorzuheben, dass der Auftragseingang, die -übermittlung und die -verarbeitung eine gewisse Zeitdauer in Anspruch nehmen können. In dieser Arbeit wird davon ausgegangen, dass diese Zeitdauer null beträgt. Sollte diese Annahme allerdings nicht zutreffen, muss bei der folgenden Analyse berücksichtigt werden, dass sich die verbleibende Durchlaufzeit für einen Wertschöpfungsschritt um die entsprechende Zeitdauer verlängert, weil diese Zeit zusätzlich benötigt wird, bis die Bestellung für die Planung der weiteren Schritte zur Verfügung steht.

schöpfungsschritten verbunden sind, gemessen werden. Ein Verfahren zur Erfassung dieser Werte wird im nächsten Abschnitt vorgestellt, bevor das Vorgehen zur Ermittlung der Entkopplungspunktposition in Abschnitt 6.3 erläutert wird.

6.2. Erfassung der Durchlauf- und Lieferzeiten

Bevor das Vorgehen zur Erfassung der Durchlauf- und Lieferzeiten erklärt wird, müssen noch die Bedeutung unterschiedlicher Aggregationsebenen für den Entkopplungspunkt sowie die Relevanz von Produktionsaufträgen für die Wertschöpfung in einer Supply Chain erläutert werden, da diese direkten Einfluss darauf ausüben.

Bedeutung von Aggregationsebenen und Produktionsaufträgen für den Entkopplungspunkt

Die Position des Entkopplungspunkts hängt direkt von der betrachteten Aggregationsebene ab. Sowohl das Bestellverhalten als auch die Durchlaufzeiten der Wertschöpfungskette können für verschiedene Aggregationsebenen unterschiedlich und damit die Entkopplungspunktposition eine andere sein. Die Berücksichtigung unterschiedlicher Aggregationsebenen bei der Erfassung des Bestellverhaltens sowie der Durchlaufzeiten der Wertschöpfungskette ist deshalb besonders wichtig.

Es wird in dieser Arbeit davon ausgegangen, dass der Entkopplungspunkt für eine Aggregationsebene A bestimmt werden soll, die eine Menge von Kunden I, Produkten J und Bestellungseingangsstellen K umfasst. Das verallgemeinerte Auftragsprofil beachtet verschiedene Aggregationsebenen, wie in Kapitel 3 detailliert beschrieben. Die Erfassung des Bestellverhaltens für eine Aggregationsebene A durch das verallgemeinerte Auftragsprofil ist deshalb unproblematisch.

Die Ausführung eines jeden Wertschöpfungsschritts basiert hingegen auf einem Produktionsauftrag. Domschke u.a. (1997, S. 15–17) definieren einen solchen Produktions- bzw. Fertigungsauftrag als die Anweisung, ein bestimmtes Vor-, Zwischen- oder Endprodukt herzustellen und den entsprechend notwendigen Wertschöpfungsschritt durchzuführen. Er ist ein Ergebnis der Planungsprozesse einer Supply Chain, wie sie zuvor in Kapitel 2 beschrieben wurden. Ein Produktionsauftrag ist immer der Auslöser für die Durchführung eines Wertschöpfungsschritts. Die Produkte, deren Fertigung ein solcher Produktionsauftrag umfasst, müssen dabei nicht deckungsgleich zur betrachteten Menge J sein. Analog zur Definition eines Loses von Domschke u.a. (1997, S. 15–17) bezieht sich ein Produktionsauftrag in dieser Arbeit auf eine Rüstfamilie. Eine solche Rüstfamilie enthält nur Produkte, die keine signifikanten Rüstzeiten verursachen, wenn sie unmittelbar nacheinander gefertigt werden.³

Das Beispiel des Porzellanherstellers eignet sich hier sehr gut, um die Abgrenzung von Rüstfamilien exemplarisch darzustellen. Betrachtet wird mit dem Einfärben der vierte Schritt in dessen Wertschöpfungskette. Produkte in unterschiedlichen Farben gehören hier verschiedenen Rüstfamilien an, da die Reinigung der Maschinen zum Entfernen der Farbe sehr aufwendig ist. Sämtliche Schläuche, die Farbreste enthalten, müssen sorgfältig

³In der Realität kann sich ein Produktionsauftrag auch auf eine andere Menge von Produkten beziehen, die aber auch nicht identisch zu der Menge J sein muss.

gereinigt werden. Erst nach dieser Reinigung können anders einzufärbende Produkte diesen Schritt durchlaufen. Sollen die Produkte allerdings die gleiche Farbe bekommen, gehören sie einer Rüstfamilie an. Blaue Tassen und Schüsseln gehören also beim Einfärben einer Rüstfamilie an, während gelbe und grüne Teller hier nicht in einer Rüstfamilie enthalten sein können.

Eine andere Situation liegt im zweiten Schritt bei der Erstellung der Rohlinge vor. Hier ist die Form der Produkte ausschlaggebend für die Rüstzeit, wobei der Wechsel der Formen längere Rüstzeiten verursacht. Tassen, Teller oder Schüsseln sind hier unabhängig von der späteren Farbe auf drei überschneidungsfreie Rüstfamilien aufgeteilt.

Es wird davon ausgegangen, dass es der Supply Chain möglich ist, ex-post die tatsächlich benötigte Durchlaufzeit für jede Ausführung eines Wertschöpfungsschritts zu messen. Computersysteme können die Supply Chain bei der Erfassung dieser Durchlaufzeiten unterstützen. Die Herausforderung für die Supply Chain besteht nun darin, die relevanten Durchlaufzeiten für die Bestellungen in der Aggregationsebene A zu ermitteln.

Bei der Bestimmung der benötigten Durchlaufzeit eines Wertschöpfungsschritts für eine Bestellung aus der Aggregationsebene A sind zwei Situationen zu unterscheiden:

1. Die für die Bestellung relevante Ausführung des Wertschöpfungsschritts kann eindeutig ermittelt werden
2. Die für die Bestellung relevante Ausführung des Wertschöpfungsschritts kann nicht eindeutig ermittelt werden

In der ersten Situation ist die Ermittlung der Durchlaufzeit einfach. Da die relevante Ausführung des Wertschöpfungsschritts für die Bestellung eindeutig identifiziert werden kann, ist es auch möglich die benötigte Durchlaufzeit genau zu bestimmen.

Ist diese eindeutige Zuordnung einer Bestellung zu der Ausführung eines Wertschöpfungsschritts für die letzten k Schritte in der Wertschöpfungskette möglich, dann kann auch die verbleibende Durchlaufzeit für diese k -letzten Schritte durch die im letzten Abschnitt beschriebene Addition genau berechnet werden. Durch einen Abgleich mit der Vorlaufzeit für diese Bestellung kann genau bestimmt werden, für die Planung welcher dieser k -letzten Wertschöpfungsschritte die Bestellung bereits vorlag.

Es ist dabei hervorzuheben, dass es auch Wertschöpfungsschritte upstream vom Entkopplungspunkt geben kann, für die eine eindeutige Zuordnung einer Ausführung zu einer Bestellung möglich ist. Sind die in diesem Schritt gefertigten Zwischenprodukte beispielsweise durch Seriennummern eindeutig zu identifizieren, dann kann ex-post auch ermittelt werden, in welchen Endprodukten diese verbaut und für welche Bestellungen sie somit verwendet wurden.

Schwieriger ist die Bestimmung der Durchlaufzeit in der zweiten Situation, wenn eine eindeutige Zuordnung einer Bestellung zu der Ausführung eines Wertschöpfungsschritts nicht möglich ist. Es ist dabei hervorzuheben, dass es auch Wertschöpfungsschritte downstream vom Entkopplungspunkt geben kann, für die diese Situation auftreten kann. Denn obwohl die Aufträge bereits vorliegen und bekannt sind, kann es sein, dass die Supply Chain diese nicht in der Planung und Durchführung der Wertschöpfungsschritte einbezieht. Es ist dann ex-post nicht nachvollziehbar, für welche Bestellungen ein Wertschöp-

fungsschritt ausgeführt wurde.

Die Durchlaufzeiten können in diesem Fall durch die Berechnung von Mittelwerten näherungsweise bestimmt werden. In dieser Arbeit werden zur Ermittlung der Durchschnittswerte alle gemessenen Durchlaufzeiten eines Wertschöpfungsschritts miteinbezogen, die sich auf eine Rüstkfamilie beziehen, die mindestens ein Produkt aus **A** enthält.

Will der betrachtete Porzellanhersteller beispielsweise den Entkopplungspunkt für blaue Tassen messen und ist er bei der Bestimmung der Durchlaufzeit für den zweiten Schritt zur Erstellung der Rohlinge auf die Berechnung von Durchschnittswerten angewiesen, so wird er alle gemessenen Durchlaufzeiten für die Fertigung von Tassenrohlingen in die Ermittlung der Durchschnittswerte einbeziehen. Die Durchlaufzeiten für die Erstellung von Schlüssel- oder Tellerrohlingen sind für ihn in diesem Fall nicht relevant, da diese Rohlinge für die Fertigung der betrachteten blauen Tassen nicht benutzt werden können. Die hergestellten Tassenrohlinge können auch für Produkte in anderen Farben verwendet werden. Da eine genaue Zuordnung einzelner Bestellungen zu den verschiedenen Ausführungen des Wertschöpfungsschritts nicht möglich ist, kann auf diese Weise aber zumindest ein glaubwürdiger Näherungswert für die benötigte Durchlaufzeit zur Herstellung von Rohlingen für blaue Tassen ermittelt werden.

Bei der Auswahl der Aggregationsebene bleibt zu beachten, dass nicht jede Ebene **A** für die Bestimmung des Entkopplungspunkts geeignet ist. So ist die Nutzung beispielsweise nicht zweckmäßig, wenn die betrachtete Aggregationsebene verschiedene Kombinationen aus Kunden, Produkten und Bestellungseingangsstellen enthält, für die Wertschöpfungskette und Entkopplungspunkt grundlegend unterschiedliche Eigenschaften aufweisen.

Es muss festgelegt werden, welche Aggregationsebenen für die Nutzung des Entkopplungspunktkonzepts geeignet sind und welche nicht. Eine erste Analyse diesbezüglich wurde von Hoekstra und Romme (1991, S. 8 ff.) durchgeführt. Sie beziehen den Entkopplungspunkt stets auf eine Aggregationsebene, die als *Produkt-Markt-Kombination* bezeichnet wird. Dabei entwickeln Hoekstra und Romme (1991, S. 111 ff.) einen umfangreichen Kriterienkatalog, der es erlaubt, Inkonsistenzen in den Charakteristika einer Aggregationsebene zu identifizieren und diese somit klar abzugrenzen. Der Einsatz des Entkopplungspunktkonzepts ist nur zweckmäßig, wenn die betrachtete Aggregationsebene bezüglich der betrachteten Charakteristika weitestgehend konsistent ist. Es wird für die weiteren Untersuchungen davon ausgegangen, dass eine beliebige und bezüglich des Kriterienkatalogs von Hoekstra und Romme (1991, S. 111 ff.) konsistente Aggregationsebene **A** verwendet wird. Dieser Kriterienkatalog setzt auch voraus, dass das Bestellverhalten und die Durchlaufzeiten der Wertschöpfungsschritte für alle Produkte in der Aggregationsebene **A** konsistent sind. Unterscheiden sich die Durchlaufzeiten der Wertschöpfungsschritte beim Porzellanhersteller für Tassen und Teller also grundlegend, dann dürfen die Produkte bei der Bestimmung des Entkopplungspunkts nicht in einer Aggregationsebene betrachtet werden. Enthält die Aggregationsebene **A** Kombinationen aus Kunden, Produkten und Bestellungseingangsstellen, die inkonsistente Durchlaufzeiten aufweisen, dann müssen diese auf mehrere konsistente Aggregationsebenen aufgeteilt und die folgende Untersuchung jeweils separat durchgeführt werden.

Vorgehen zur Erfassung der durchschnittlichen Durchlaufzeiten

Die Durchlaufzeit eines Wertschöpfungsschritts umfasst nicht nur die reine Fertigungsdauer, in der Vor-, Zwischen- und Endprodukte physisch erstellt werden. Wie bereits Domschke u.a. (1997, S. 26–28) erkannt haben, beinhaltet die Durchlaufzeit auch Rüst- und Wartezeiten, die berücksichtigt werden müssen. Der Zusammenhang zwischen den verschiedenen Zeiten ist in Abbildung 6.5 dargestellt.




Abbildung 6.5.: Zusammenhang zwischen Rüst-, Fertigungs-, Warte- und Durchlaufzeit

Die Rüstzeit wurde bereits von Domschke und Scholl (1999, S. 116) als die Zeitdauer definiert, die zur Umstellung der Fertigung auf einen Produktionsauftrag notwendig ist. Zusammen mit der tatsächlichen Fertigungszeit ergibt die Rüstzeit die Zeitdauer, in der ein Produktionsauftrag die für die Fertigung notwendige Ressource (bspw. eine Maschine) belegt. Es kann während dieser Zeitdauer entsprechend kein anderer Produktionsauftrag mittels dieser Ressource weiterverarbeitet werden. In Abbildung 6.5 ist diese Zeitdauer für die Ausführung zweier Produktionsaufträge für die Rüstfamilie RF1 durch graue Boxen hervorgehoben.

Die Zeitdauer zwischen zwei aufeinanderfolgenden Ausführungen eines Produktionsauftrags für die gleiche Rüstfamilie wird als Wartezeit beschrieben. In Abbildung 6.5 ist die Wartezeit für die Rüstfamilie RF1 zwischen den Ausführungen der beiden Produktionsaufträge exemplarisch markiert. In dieser Zeit werden die Ressourcen, die für diesen Wertschöpfungsschritt benötigt werden, zur Herstellung von Produkten aus anderen Rüstfamilien eingesetzt. Im vierten Wertschöpfungsschritt beim Porzellanhersteller ist dies die Maschine zum Einfärben der Rohlinge. Zwischen zwei Ausführungen des Wertschöpfungsschritts für rote Produkte können Rohlinge blau, grün, schwarz und gelb eingefärbt werden. Wird für Rohlinge, die rot eingefärbt werden sollen, der dritte Wertschöpfungsschritt abgeschlossen, während auf den Ressourcen des vierten Wertschöpfungsschritts ein Produktionsauftrag für eine andere Farbe läuft, muss mit deren Weiterverarbeitung gewartet werden. Das Färben der andersfarbigen Produkte muss zunächst beendet werden, bevor ein entsprechender Produktionsauftrag für das Färben in Rot gestartet werden kann.

Die Wartezeit ist die Zeitdauer, in der auf die Weiterverarbeitung eines Zwischenprodukts gewartet werden muss, weil die notwendigen Ressourcen für die Fertigung anderer

Produkte eingesetzt werden. Da in dieser Analyse der kritische Pfad betrachtet wird, verlängern solche Wartezeiten die Zeitdauer, die zum Abschluss der Wertschöpfungskette und Auslieferung der Bestellungen benötigt wird. Die Wartezeiten müssen deshalb in den Durchlaufzeiten berücksichtigt werden, wie bereits Domschke und Scholl (1999, S. 116) erkannten.

Die Zeitdauer zwischen zwei Ausführungen eines Wertschöpfungsschritts für die gleiche Rüstfamilie entspricht dabei der Wartezeit, da in dieser Zeit die Fertigung der entsprechenden Produkte nicht fortgeführt wird, sondern auf die nächste Ausführung des Wertschöpfungsschritts gewartet wird. Die Summe aus Rüst-, Fertigungs- und Wartezeit ergibt, wie in Abbildung 6.5 eingezeichnet, die Durchlaufzeit eines Wertschöpfungsschritts. Es ist die Zeitdauer zwischen den Startzeitpunkten zweier aufeinanderfolgender Produktionsaufträge für die gleiche Rüstfamilie. Sie kann als Differenz dieser zwei Startzeitpunkte einfach berechnet werden.

Um die durchschnittliche Durchlaufzeit eines Wertschöpfungsschritts zu bestimmen, muss nun das arithmetische Mittel über alle so gemessenen Durchlaufzeiten gebildet werden. Das Vorgehen zur Berechnung der durchschnittlichen Durchlaufzeiten wird hier am Beispiel des Porzellanherstellers vorgeführt.

Der kritische Pfad in der Wertschöpfungskette des Porzellanherstellers wurde bereits in Abbildung 6.2 dargestellt. Hergestellt werden, wie bereits zuvor erwähnt, Tassen, Teller und Schüsseln in den Farben Blau, Rot, Grün, Gelb und Schwarz. Die Rüstfamilien bei der Erstellung der Rohlinge und der Glasur beziehen sich auf die Form des Produkts (Tassen, Teller oder Schüsseln), da die Maschinen auf deren Gestaltung ausgelegt werden müssen. Beim Farbdekor werden die Rüstfamilien nach Farben unterschieden, da die Reinigung der Maschinen für die Umstellung der Farbe besonders aufwendig ist. Die Bemalung erfolgt immer auf Basis eines Kundenwunschs und dauert eine Zeiteinheit. Die Auslieferung erfolgt umgehend nach der Bemalung und dauert 2 Zeiteinheiten. Die Durchlaufzeiten für die Erstellung der Rohlinge, die Glasur und das Farbdekor jeweils mit Brand kann auf Grundlage der in den folgenden Tabellen 6.1 bis 6.3 aufgelisteten Informationen ermittelt werden. Diese Tabellen enthalten die Produktaufträge für diese drei Schritte zwischen den fiktiven Zeitpunkten 0 und 80 mit Anfangs- und Endzeitpunkt, wobei die Rüstzeiten darin enthalten sind.

Die ebenfalls in den Tabellen enthaltenen Durchlaufzeiten wurden als Zeitdauer bis zum Beginn des nächsten Produktionsauftrags für die gleiche Rüstfamilie berechnet. Es ist die jeweilige Zeitdauer vom Anfangszeitpunkt eines Produktionsauftrags bis zum Beginn des nächsten Auftrags für die gleiche Rüstfamilie. So beginnt zum Zeitpunkt 9 beispielsweise der Produktionsauftrag *Rohling_ Tasse_ 02* zur Erstellung von Rohlingen für Tassen. Der nächste Produktionsauftrag zur Erstellung von Rohlingen für Tassen *Rohling_ Tasse_ 03* fängt zum Zeitpunkt 15 an. Die Differenz aus 9 und 15 ergibt die Durchlaufzeit von 6 Zeiteinheiten für *Rohling_ Tasse_ 02*.

Die durchschnittlichen Durchlaufzeiten können als arithmetisches Mittel nun einfach bestimmt werden. Für Schüsseln wurden beispielsweise bei der Erstellung der Rohlinge Durchlaufzeiten von 15, 10, 14, 7, 11 und 10 Zeiteinheiten gemessen. Das arithmetische Mittel dieser sechs Werte und die durchschnittliche Durchlaufzeit in diesem Beispiel betragen 11,2 Zeiteinheiten. Die durchschnittlichen Durchlaufzeiten für die anderen Wert-

6. Einfluss des Bestellverhaltens auf den Entkopplungspunkt

Produktionsauftrag	Anfangszeitpunkt	Endzeitpunkt	Durchlaufzeit
<i>Rohling_Tasse_01</i>	0	2	9
<i>Rohling_Teller_01</i>	2	5	10
<i>Rohling_Schüssel_01</i>	5	9	15
<i>Rohling_Tasse_02</i>	9	12	6
<i>Rohling_Teller_02</i>	12	15	5
<i>Rohling_Tasse_03</i>	15	17	10
<i>Rohling_Teller_03</i>	17	20	10
<i>Rohling_Schüssel_02</i>	20	25	10
<i>Rohling_Tasse_04</i>	25	27	10
<i>Rohling_Teller_04</i>	27	30	11
<i>Rohling_Schüssel_03</i>	30	35	14
<i>Rohling_Tasse_05</i>	35	38	5
<i>Rohling_Teller_05</i>	38	40	4
<i>Rohling_Tasse_06</i>	40	42	8
<i>Rohling_Teller_06</i>	42	44	13
<i>Rohling_Schüssel_04</i>	44	48	7
<i>Rohling_Tasse_07</i>	48	51	10
<i>Rohling_Schüssel_05</i>	51	55	11
<i>Rohling_Teller_07</i>	55	58	5
<i>Rohling_Tasse_08</i>	58	60	8
<i>Rohling_Teller_08</i>	60	62	9
<i>Rohling_Schüssel_06</i>	62	66	10
<i>Rohling_Tasse_09</i>	66	69	9
<i>Rohling_Teller_09</i>	69	72	8
<i>Rohling_Schüssel_07</i>	72	75	
<i>Rohling_Tasse_10</i>	75	77	
<i>Rohling_Teller_10</i>	77	80	

Tabelle 6.1.: Exemplarisch gemessene Durchlaufzeiten für den zweiten Wertschöpfungsschritt beim Porzellanhersteller (Erstellung Rohling & 1. Brand)

6. Einfluss des Bestellverhaltens auf den Entkopplungspunkt

Produktionsauftrag	Anfangszeitpunkt	Endzeitpunkt	Durchlaufzeit
<i>Glasur_Tasse_01</i>	0	4	6
<i>Glasur_Teller_01</i>	4	6	6
<i>Glasur_Tasse_02</i>	6	10	9
<i>Glasur_Teller_02</i>	10	12	9
<i>Glasur_Schüssel_01</i>	12	15	9
<i>Glasur_Tasse_03</i>	15	19	10
<i>Glasur_Teller_03</i>	19	21	9
<i>Glasur_Schüssel_02</i>	21	25	10
<i>Glasur_Tasse_04</i>	25	28	10
<i>Glasur_Teller_04</i>	28	31	11
<i>Glasur_Schüssel_03</i>	31	35	17
<i>Glasur_Tasse_05</i>	35	39	6
<i>Glasur_Teller_05</i>	39	41	7
<i>Glasur_Tasse_06</i>	41	46	10
<i>Glasur_Teller_06</i>	46	48	12
<i>Glasur_Schüssel_04</i>	48	51	7
<i>Glasur_Tasse_07</i>	51	55	9
<i>Glasur_Schüssel_05</i>	55	58	10
<i>Glasur_Teller_07</i>	58	60	5
<i>Glasur_Tasse_08</i>	60	63	7
<i>Glasur_Teller_08</i>	63	65	8
<i>Glasur_Schüssel_06</i>	65	67	8
<i>Glasur_Tasse_09</i>	67	71	10
<i>Glasur_Teller_09</i>	71	73	4
<i>Glasur_Schüssel_07</i>	73	75	
<i>Glasur_Teller_10</i>	75	77	
<i>Glasur_Tasse_10</i>	77	80	

Tabelle 6.2.: Exemplarisch gemessene Durchlaufzeiten für den dritten Wertschöpfungsschritt beim Porzellanhersteller (Glasur & 2. Brand)

6. Einfluss des Bestellverhaltens auf den Entkopplungspunkt

Produktionsauftrag	Anfangszeitpunkt	Endzeitpunkt	Durchlaufzeit
<i>Färben_Blau_01</i>	0	2	6
<i>Färben_Rot_01</i>	2	6	11
<i>Färben_Blau_02</i>	6	8	5
<i>Färben_Grün_01</i>	8	11	21
<i>Färben_Blau_03</i>	11	13	12
<i>Färben_Rot_02</i>	13	16	12
<i>Färben_Gelb_01</i>	16	20	20
<i>Färben_Schwarz_01</i>	20	23	11
<i>Färben_Blau_04</i>	23	25	11
<i>Färben_Rot_03</i>	25	29	20
<i>Färben_Grün_02</i>	29	31	30
<i>Färben_Schwarz_02</i>	31	34	10
<i>Färben_Blau_05</i>	34	36	5
<i>Färben_Gelb_02</i>	36	39	17
<i>Färben_Blau_06</i>	39	41	11
<i>Färben_Schwarz_03</i>	41	45	31
<i>Färben_Rot_04</i>	45	50	17
<i>Färben_Blau_07</i>	50	53	7
<i>Färben_Gelb_03</i>	53	57	24
<i>Färben_Blau_08</i>	57	59	8
<i>Färben_Grün_03</i>	59	62	10
<i>Färben_Rot_05</i>	62	65	5
<i>Färben_Blau_09</i>	65	67	
<i>Färben_Rot_06</i>	67	69	
<i>Färben_Grün_04</i>	69	72	
<i>Färben_Schwarz_04</i>	72	77	
<i>Färben_Gelb_04</i>	77	80	

Tabelle 6.3.: Exemplarisch gemessene Durchlaufzeiten für den vierten Wertschöpfungsschritt beim Porzellanhersteller (Farbdekor & 3. Brand)

schöpfungsschritte und Rüstfamilien können Abbildung 6.6 entnommen werden.



Abbildung 6.6.: Durchschnittliche Durchlaufzeiten je Rüstfamilie beim Porzellanhersteller

Wie bereits im letzten Abschnitt beschrieben, kann durch einen Abgleich der Vorlaufzeit mit der verbleibenden Durchlaufzeit für einen Wertschöpfungsschritt ermittelt werden, ob ein Auftrag rechtzeitig vorlag, um für die Planung des Schritts verwendet werden zu können. Zur Bestimmung der Entkopplungspunktposition muss deshalb für jeden Wertschöpfungsschritt die durchschnittlich verbleibende Durchlaufzeit berechnet werden. Sie kann für jede Stelle in der Wertschöpfungskette durch die Addition der durchschnittlichen Durchlaufzeiten aller auf dem kritischen Pfad verbleibenden Schritte errechnet werden. In Abbildung 6.7 wird dies für die Stelle direkt vor dem o -ten Wertschöpfungsschritt exemplarisch dargestellt, wobei der kritische Pfad nach dem p -ten Schritt endet. Die durchschnittliche Durchlaufzeit eines beliebigen Schritts q auf der betrachteten Aggregationsebene A wird mit DLZ_{Aq} abgekürzt. Die Summe der durchschnittlichen Durchlaufzeiten für die Schritte o bis p ergibt die durchschnittlich verbleibende Durchlaufzeit vor dem o -ten Schritt. Sie entspricht gleichzeitig der durchschnittlich verbleibenden Lieferzeit LZ_{Ao} für den o -ten Schritt.

Wie bereits erläutert, dürfen nur konsistente Aggregationsebenen A betrachtet werden, die vergleichbare Wertschöpfungsschritte und Durchlaufzeiten aufweisen. In dem Porzel-




Abbildung 6.7.: Durchschnittlich verbleibende Durchlauf- und Lieferzeit

lanherstellungsbeispiel variieren die Durchlaufzeiten bei Betrachtung unterschiedlicher Formen und Farben stark. Das Färben einer gelben Tasse dauert 20,3 Zeiteinheiten, während für eine blaue Tasse nur 8,1 Zeiteinheiten benötigt werden.

Auch bei den verbleibenden Durchlauf- bzw. Lieferzeiten sind diese Unterschiede zu beobachten. Die durchschnittlich verbleibenden Lieferzeiten für vier Produkte mit unterschiedlichen Farben und Formen sind in Abbildung 6.8 aufgeführt. Sie wurden auf Basis der Werte aus Abbildung 6.6 berechnet. Als Beispiel wurden hier blaue Tassen, gelbe und grüne Tassen, rote Teller sowie schwarze Schüsseln verwendet. Mit Beginn des dritten Schritts (Glasur & 2. Brand) beträgt die durchschnittlich verbleibende Durchlaufzeit für blaue Tassen beispielsweise 19,7 Zeiteinheiten. Sie resultiert aus der Addition der folgenden durchschnittlichen Durchlaufzeiten:

- Glasur & 2. Brand für Tassen: 8,6 Zeiteinheiten
- Farbdekor & 3. Brand für blaue Produkte: 8,1 Zeiteinheiten
- Bemalung: 1,0 Zeiteinheiten
- Auslieferung: 2,0 Zeiteinheiten

Für gelbe Tassen wurde hingegen eine durchschnittlich verbleibende Durchlaufzeit von 31,9 Zeiteinheiten gemessen. Sie entspricht der Summe der folgenden durchschnittlichen Durchlaufzeiten:

- Glasur & 2. Brand für Tassen: 8,6 Zeiteinheiten
- Farbdekor & 3. Brand für gelbe Produkte: 20,3 Zeiteinheiten
- Bemalung: 1,0 Zeiteinheiten
- Auslieferung: 2,0 Zeiteinheiten



Abbildung 6.8.: Durchschnittlich verbleibende Durchlaufzeiten beim Porzellanhersteller

Durch die durchschnittlich längere Durchlaufzeit für das Färben von gelben Tassen ist auch die verbleibende Durchlaufzeit zu Beginn des dritten Schritts länger als bei blauen Tassen.

Einzig für grüne und gelbe Produkte ist die Durchlaufzeit für das Färben identisch. Gelbe und grüne Produkte einer Form dürfen entsprechend gemeinsam untersucht werden, weil ihre Wertschöpfungsschritte die gleiche Durchlaufzeit aufweisen. Produkte mit anderen Farben und Formen müssen allerdings separat analysiert werden, weil die folgende Analyse ansonsten zu fehlerhaften Rückschlüssen führen kann, wie im nächsten Abschnitt noch erklärt wird.

Das Vorgehen zur Erfassung der durchschnittlichen Durchlauf- und Lieferzeiten ist damit hier abgeschlossen. Bevor das Verfahren zur Bestimmung des Entkopplungspunkts vorgestellt wird, muss noch auf einen wichtigen Aspekt hingewiesen werden. Das hier eingeführte Verfahren ist auf die Betrachtung durchschnittlicher Durchlauf- und Lieferzeiten beschränkt. Eine Streuung bei diesen Zeiten wird hier nicht explizit berücksichtigt. So beträgt die durchschnittlich Durchlaufzeit für das Färben blauer Produkte des Porzellan-

herstellers beispielsweise 8,1 Zeiteinheiten. Wie Tabelle 6.3 zu entnehmen ist, kann die Durchlaufzeit für einzelne Ausführungen allerdings zwischen 5 Zeiteinheiten (Produktionsauftrag *Färben_Blau_02*) und 12 Zeiteinheiten (Produktionsauftrag *Färben_Blau_03*) schwanken. Diese Streuung wird in die folgende Analyse nicht miteinbezogen. Sie kann allerdings durchaus von Bedeutung sein, beispielsweise wenn eine Supply Chain die Durchlaufzeiten auf die Lieferzeitanforderungen verschiedener Kunden abstimmt. Mögliche Konsequenzen dieses Vorgehens werden im nächsten Abschnitt aufgegriffen und erläutert.

6.3. Verfahren zur ex-post Bestimmung des Entkopplungspunkts

Wie bereits in Abschnitt 6.1 erläutert, müssen drei Situationen mit verschiedenen Grundlagen für die Planung eines Wertschöpfungsschritts unterschieden werden:

1. Eine rein auftragsbasierte Planung
2. Eine Kombination aus auftrags- und prognosebasierter Planung
3. Eine rein prognosebasierte Planung

Um den Entkopplungspunkt in einer Wertschöpfungskette ex-post zu bestimmen, müssen diese drei verschiedenen Situationen ermittelt und voneinander abgegrenzt werden. Die in Abbildung 6.9 eingezeichnete Wertschöpfungskette zeigt die drei Situationen durch die unterschiedliche Färbung der einzelnen Schritte.

Wie im letzten Abschnitt ist bei der Analyse, ob eine Bestellung für die Planung eines Wertschöpfungsschritts bereits vorlag, zwischen zwei Situationen zu unterscheiden. In dem einen Fall kann die relevante Ausführung des Wertschöpfungsschritts für eine Bestellung eindeutig ermittelt werden und im anderen Fall nicht.

Wenn es möglich ist für die k -letzten Wertschöpfungsschritte die relevanten Ausführungen für eine Bestellung exakt zu bestimmen, dann kann auch die verbleibende Lieferzeit für jeden dieser Schritte genau berechnet werden. Durch ein Vergleich mit der Vorlaufzeit kann ex-post eindeutig ermittelt werden, für die Planung welcher Wertschöpfungsschritte diese Bestellung bereits vorlag. Es sind genau die Wertschöpfungsschritte, deren verbleibende Lieferzeit nicht größer als die Vorlaufzeit der jeweiligen Bestellung ist.

Sollte die Zuordnung einer Bestellung zu der Ausführung eines Wertschöpfungsschritts nicht möglich sein, muss stattdessen ein Näherungswert für die Durchlaufzeit dieses Schritts in der Analyse benutzt werden. Für diese Wertschöpfungsschritte wird statt der genauen Durchlaufzeit die ebenfalls im letzten Abschnitt beschriebene durchschnittliche Durchlaufzeit verwendet. Auf diese Weise kann für jede Bestellung näherungsweise ermittelt werden, für die Planung welcher Wertschöpfungsschritte sie bereits zur Verfügung stand. Nachdem diese Analyse für jede Bestellung aus der Aggregationsebene **A** durchgeführt wurde, kann für jeden Wertschöpfungsschritt der Anteil der Bestellungen berechnet werden, der für die Planung bereits vorlag. Auf diese Weise kann jeder Wertschöpfungsschritt




Abbildung 6.9.: Planungsgrundlage in Abhängigkeit von verbleibender Lieferzeit

einer der drei Situationen aus Abbildung 6.9 zugeordnet und der Entkopplungspunkt bestimmt werden.

In einem Extremfall ist es für keinen Wertschöpfungsschritt möglich, eine Bestellung einer konkreten Ausführung eines Schritts zuzuordnen. In dieser Situation müssen für alle Wertschöpfungsschritte die durchschnittlichen Durchlaufzeiten in der Analyse betrachtet werden. Wie in einem solchen Fall mit den Kennzahlen aus Kapitel 5 die drei unterschiedlichen Situationen aus Abbildung 6.9 näherungsweise bestimmt werden können, wird in den folgenden Ausführungen erläutert.

Der in Kapitel 5 definierte Anfangspunkt $K_{1,Start}(t_1, t_n, A)$ entspricht rückblickend der längsten Vorlaufzeit, zu der stets alle Bestellungen eingegangen sind. Überschreitet die durchschnittlich verbleibende Lieferzeit eines Wertschöpfungsschritts diesen Anfangspunkt nicht, dann ist selbst die Vorlaufzeit der kurzfristigsten Bestellungen länger als die durchschnittlich verbleibende Durchlaufzeit gewesen, um die restlichen Schritte in der Wertschöpfung auszuführen und die Verarbeitung und Auslieferung abzuschließen. Im Durchschnitt genügte es also, mit der Durchführung dieses Schritts zu einem Zeitpunkt zu beginnen, zu dem die gesamte Nachfrage in Form von Aufträgen vorlag, ohne eine pünktliche Auslieferung zum Wunschlieferszeitpunkt zu gefährden. Eine rein auftragsbasierte Planung dieses Wertschöpfungsschritts war also durchschnittlich möglich. Es muss hervorgehoben werden, dass diese Analyse nur die durchschnittlichen Durchlaufzeiten betrachtet und eine mögliche Streuung zwischen verschiedenen Ausführungen eines Wertschöpfungsschritts nicht untersucht. Die Effekte, die eine solche Streuung haben kann,

werden am Ende dieses Abschnitts beschrieben. In Abbildung 6.9 sind die Schritte, die rein auftragsbasiert geplant werden können, weiß eingezeichnet. Bei Betrachtung eines beliebigen Wertschöpfungsschritts o mit einer durchschnittlich verbleibenden Lieferzeit LZ_{Ao} muss $LZ_{Ao} \leq K_{1,Start}(t_1, t_n, \mathbf{A})$ gelten, damit eine rein auftragsbasierte Planung im Durchschnitt durchführbar war.

Das andere Ende der Spannweite des Bestellungseingangs markiert der Endpunkt, der ebenfalls in Kapitel 5 als $K_{1,End}(t_1, t_n, \mathbf{A})$ definiert wurde. Er entspricht der kürzesten Vorlaufzeit, zu der keine längerfristigen Bestellungen vorgelegen haben. Überschreitet die durchschnittlich verbleibende Lieferzeit eines Wertschöpfungsschrittes diesen Endpunkt, haben selbst die langfristigen Bestellungen eine Vorlaufzeit, die kürzer als die durchschnittlich verbleibende Durchlaufzeit der bis zu Abschluss und Auslieferung noch ausstehenden Schritte war. Mit der Durchführung dieses Schrittes musste deshalb vor dem Eingang der langfristigen Bestellungen angefangen werden, um eine Auslieferung zum Wunschlieferzeitpunkt durchschnittlich zu gewährleisten. Für die Planung liegen dann im Durchschnitt noch keine Aufträge vor, weshalb sie rein prognosebasiert ausgeführt werden musste. Für die in Abbildung 6.9 dunkelgrau markierten Wertschöpfungsschritte war eine solche prognosebasierte Planung notwendig. Gilt also für einen beliebigen Wertschöpfungsschritt o , dessen durchschnittlich verbleibende Lieferzeit LZ_{Ao} beträgt, $LZ_{Ao} > K_{1,End}(t_1, t_n, \mathbf{A})$, dann muss dieser Schritt durchschnittlich rein prognosebasiert geplant werden.

In der dritten Situation liegt die durchschnittlich verbleibende Lieferzeit zwischen dem Anfangs- und Endpunkt. In dieser Situation war ein Teil der Nachfrage in Form von Bestellungen bereits eingegangen. Allerdings werden noch weitere Bestellungen für den Wunschlieferzeitpunkt eingehen. In der Planung konnten die vorliegenden Bestellungen in Kombination mit einer Prognose für die noch ausstehende Menge verwendet werden. Bei den in Abbildung 6.9 hellgrau dargestellten Schritten war eine solche Planung, die auf einer Kombination aus Aufträgen und Prognosen basiert, möglich. Für einen beliebigen Wertschöpfungsschritt o mit einer durchschnittlich verbleibenden Lieferzeit LZ_{Ao} gilt in einer solchen Situation $LZ_{Ao} > K_{1,Start}(t_1, t_n, \mathbf{A})$ und $LZ_{Ao} \leq K_{1,End}(t_1, t_n, \mathbf{A})$. Die in den beiden folgenden Kapiteln untersuchten ADI-basierten Prognosemethoden sind eine Möglichkeit, wie Aufträge und Prognosen in einer solchen Situation kombiniert werden können, um für die Planung eines Wertschöpfungsschritts die zu fertigende Menge vorherzusagen.

Die Identifikation der Planungsgrundlage für die verschiedenen Wertschöpfungsschritte und die damit verbundene Bestimmung des Entkopplungspunkts kann am Beispiel des Porzellanherstellers sehr anschaulich vorgeführt werden. Die notwendigen Durchlauf- und Lieferzeiten wurden dafür bereits im letzten Abschnitt aufgeführt. Die eingegangenen Bestellmengen d_{Aes} für blaue Tassen mit Wunschlieferzeitpunkten 71 bis 80 sind in Tabelle 6.4 und die daraus resultierenden anteilig vorliegenden Bestellmengen in Tabelle 6.5 dargestellt. Sie sind repräsentativ für das beobachtete Bestellverhalten zwischen den Zeitpunkten 0 und 80, auf die sich auch die gemessenen Durchlauf- und Lieferzeiten beziehen. Die hieraus resultierenden durchschnittlich anteilig vorliegenden Bestellmengen sind in Tabelle 6.6 aufgeführt. Die Werte wurden mit den in Kapitel 3 vorgestellten Formeln berechnet.

6. Einfluss des Bestellverhaltens auf den Entkopplungspunkt

d_{Aes}	<i>Wunschlieferzeitpunkt</i>									
<i>Vorlaufzeit</i>	71	72	73	74	75	76	77	78	79	80
0-13	0	0	0	0	0	0	0	0	0	0
14	10	12	13	14	8	9	7	10	11	8
15	16	14	13	18	12	19	16	14	15	13
16	16	20	15	12	13	15	12	10	10	12
17	8	10	15	8	6	10	10	14	14	8
18	12	11	14	7	5	10	10	14	12	5
19	10	10	15	11	14	10	13	12	10	8
20	22	12	10	20	18	15	18	20	19	20
21	8	4	5	3	5	3	5	8	5	5
22	4	6	4	3	4	8	7	5	5	9
23+	0	0	0	0	0	0	0	0	0	0

Tabelle 6.4.: Bestellmenge blauer Tassen im Beispiel des Porzellanherstellers

X_{Aes}	<i>Wunschlieferzeitpunkt</i>									
<i>Vorlaufzeit</i>	71	72	73	74	75	76	77	78	79	80
0-13	100	100	100	100	100	100	100	100	100	100
14	100	100	100	100	100	100	100	100	100	100
15	90,6	87,9	87,5	85,4	90,6	90,9	92,9	90,7	89,1	90,9
16	75,5	73,7	75,0	66,7	76,5	71,7	76,5	77,6	74,3	76,1
17	60,4	53,5	60,6	54,2	61,2	56,6	64,3	68,2	64,4	62,5
18	52,8	43,4	46,2	45,8	54,1	46,5	54,1	55,1	50,5	53,4
19	41,5	32,3	32,7	38,5	48,2	36,4	43,9	42,1	38,6	47,7
20	32,1	22,2	18,3	27,1	31,8	26,3	30,6	30,8	28,7	38,6
21	11,3	10,1	8,7	6,3	10,6	11,1	12,2	12,1	9,9	15,9
22	3,8	6,1	3,8	3,1	4,7	8,1	7,1	4,7	5,0	10,2
23+	0	0	0	0	0	0	0	0	0	0

Tabelle 6.5.: Anteilig vorliegende Bestellmenge blauer Tassen im Porzellanherstellerbeispiel (in %)

	<i>Vorlaufzeit</i>										
$\mu(t_1, t_n, X_{\text{Aes}})$	0-13	14	15	16	17	18	19	20	21	22	23+
Blaue Tassen	100	100	90	74	61	50	40	29	11	6	0

Tabelle 6.6.: Durchschnittlich anteilig vorliegende Bestellmenge blauer Tassen im Porzellanherstellerbeispiel (in %)

Die Bestellungen für blaue Tassen gehen mit einer Vorlaufzeit zwischen 14 und 22 Zeiteinheiten ein. Für das Bestellverhalten ergibt sich ein Anfangspunkt von $K_{1,Start}(t_1, t_n, \mathbf{A}) = 14$ und ein Endpunkt von $K_{1,End}(t_1, t_n, \mathbf{A}) = 22$. Die durchschnittlich verbleibende Lieferzeit für den Schritt "Farbdekor und 3. Brand" beträgt 11,1 Zeiteinheiten und unterschreitet damit den Anfangspunkt. Zum Ausführungsbeginn dieses Schritts lagen also im Durchschnitt sämtliche Bestellungen vor. Eine rein auftragsbasierte Planung dieses sowie der beiden folgenden Schritte zur Bemalung und Auslieferung war entsprechend durchschnittlich möglich. In Abbildung 6.10 sind der Bestellungseingang für die blauen Tassen sowie die durchschnittlich verbleibenden Lieferzeiten für die Wertschöpfungsschritte exemplarisch dargestellt. Die rechte gestrichelte Linie markiert die durchschnittlich verbleibende Lieferzeit für den vierten Wertschöpfungsschritt Farbdekor und 3. Brand. Es ist direkt zu erkennen, dass zu diesem Zeitpunkt im Durchschnitt 100% der Bestellmenge vorlagen und entsprechend für die Planung des Schrittes verwendet werden konnten.

Die durchschnittlich verbleibende Lieferzeit für Glasur und 2. Brand beträgt 19,7 Zeiteinheiten. Sie ist in Abbildung 6.10 ebenfalls durch eine gestrichelte Linie hervorgehoben. Da mit einer Vorlaufzeit von 20 Zeiteinheiten durchschnittlich 29% der Bestellmenge vorlagen, somit 71% ausstehend waren, konnten die vorliegenden Aufträge zwar für die Planung dieses Schritts genutzt werden, mussten aber mit einer Prognose kombiniert werden. Die ADI-basierten Prognosemethoden, die in den nächsten beiden Kapiteln analysiert werden, erlauben es, die vorliegenden Bestellungen in die Planung der zu fertigen Menge einzubeziehen. Die durchschnittlich verbleibende Lieferzeit für die Erstellung der Rohlinge und den 1. Brand bei blauen Tassen beträgt 28,0 Zeiteinheiten und überschreitet den Endpunkt, der bei blauen Tassen 22 Zeiteinheiten beträgt. Da damit zu Beginn dieses Schritts im Durchschnitt noch keine Bestellungen vorlagen, musste dieser rein prognosebasiert geplant werden, um eine Auslieferung durchschnittlich 28 Zeiteinheiten später zum Wunschlieferzeitpunkt gewährleisten zu können. Die unterschiedlichen Planungsgrundlagen für die Wertschöpfungsschritte auf dem kritischen Pfad für blaue Tassen sind damit ermittelt und der Entkopplungspunkt bestimmt.

Allerdings ist dieser Entkopplungspunkt nicht notwendigerweise für alle Produkte des Porzellanherstellers identisch. Das durchschnittliche Bestellverhalten für die anderen exemplarischen Aggregationsebenen aus dem letzten Abschnitt ist in Tabelle 6.7 aufgeführt.

$\mu(t_1, t_n, X_{\mathbf{Aes}})$	Vorlaufzeit										
	0-15	16	17	18	19	20	21	22	23	24	25+
Grüne & gelbe Tassen	100	100	85	60	30	10	0	0	0	0	0
Rote Teller	100	100	100	100	90	80	50	40	20	10	0
Schwarze Schüsseln	100	100	100	100	90	80	50	40	20	10	0

Tabelle 6.7.: Durchschnittlich anteilig vorliegende Bestellmenge grüner & gelber Tassen, roter Teller und schwarzer Schüsseln im Porzellanherstellerbeispiel (in %)

Bei gelben und grünen Tassen betrug die durchschnittlich verbleibende Lieferzeit für Farbdekor und 3. Brand 23,3 Zeiteinheiten. Tabelle 6.7 kann entnommen werden, dass der Endpunkt in diesem Fall bei einer Vorlaufzeit von 20 Zeiteinheiten liegt. Da die

6. Einfluss des Bestellverhaltens auf den Entkopplungspunkt




Abbildung 6.10.: Vergleich der Vorlauf- und Lieferzeiten zur Bestimmung des Entkopplungspunkts für blaue Tassen im Porzellanherstellerbeispiel

durchschnittlich verbleibende Lieferzeit für Farbdekor und 3. Brand damit den Endpunkt überschreitet, musste dieser Schritt im Gegensatz zur Situation bei den blauen Tassen im Durchschnitt prognosebasiert geplant werden. Selbst die langfristigsten Aufträge wurden mit einer Vorlaufzeit aufgegeben, die einen Beginn der Ausführung dieses Schritts bereits vor dem ersten Bestellungseingang notwendig gemacht hat, um diese pünktlich zum Wunschlieferzeitpunkt auszuliefern. Einzig die Planung der Bemalung und Auslieferung erfolgt in diesem Beispiel rein auftragsbasiert.

Interessant ist die Situation für die Herstellung roter Teller und schwarzer Schüsseln. Obwohl die anteilig vorliegenden Bestellmengen für die verschiedenen Vorlaufzeiten identisch sind, ist die Grundlage für die Planung der Schritte aufgrund der unterschiedlichen durchschnittlich verbleibenden Lieferzeiten eine andere. Der Schritt “Farbdekor und 3. Brand” konnte für rote Teller rein auftragsbasiert geplant werden. Die durchschnittlich verbleibende Lieferzeit für diesen Schritt betrug 16,0 Zeiteinheiten, womit sie den Anfangspunkt unterschreitet, der in diesem Fall bei 18 Zeiteinheiten liegt. Bei schwarzen Schüsseln ist die durchschnittlich verbleibende Lieferzeit hingegen 20,3 Zeiteinheiten. Zu dieser Vorlaufzeit lagen durchschnittlich 50-80% der Bestellmenge vor. Für die Planung des Farbedekors und 3. Brands konnte entsprechend eine Kombination aus Aufträgen

und Prognosen verwendet werden.

Die Beispiele verdeutlichen, wie der Entkopplungspunkt und die verschiedenen Planungsgrundlagen in einer Supply Chain ex-post bestimmt werden können. Die Relevanz einer konsistenten Aggregationsebene für die Bestimmung des Entkopplungspunkts kann dabei an diesem Beispiel sehr gut herausgearbeitet werden. Es wird dafür angenommen, dass zur Bestimmung des Entkopplungspunkts eine Aggregationsebene betrachtet wird, die mit roten Tellern und schwarzen Schüsseln genau zwei Produkte enthält. Die Aggregationsebene weist dabei das gleiche Bestellverhalten auf, wie in Tabelle 6.7 für die jeweils einzelnen Produkte dargestellt. Zur Bestimmung der durchschnittlichen Durchlaufzeit für den vierten Wertschöpfungsschritt, in dem das Farbdekor und der 3. Brand durchgeführt werden, müssen die gemessenen Werte für rote und schwarze Produkte, die in Tabelle 6.3 aufgeführt sind, gemeinsam betrachtet werden. Für rote Produkte wurden hier Durchlaufzeiten von 11, 12, 20, 17 und 5 Zeiteinheiten gemessen, während für schwarze Produkte Durchlaufzeiten von 11, 10 und 31 Zeiteinheiten erfasst wurden. Das arithmetische Mittel über alle diese Werte ergibt eine durchschnittliche Durchlaufzeit von 14,6 Zeiteinheiten für diesen Schritt. Wenn zusätzlich in Betracht gezogen wird, dass die Durchlaufzeit für die abschließende Bemalung und Auslieferung drei Zeiteinheiten beträgt, ergibt sich für den Schritt zum Auftragen des Farbdekors eine durchschnittlich verbleibende Lieferzeit von 17,6 Zeiteinheiten. Dieser Wert unterschreitet den aus dem Bestellverhalten resultierenden Anfangspunkt, der für rote Teller und schwarze Schüsseln bei 18 Zeiteinheiten liegt. Die Schlussfolgerung daraus wäre, dass für das Farbdekor und den 3. Brand sowohl für rote Teller als auch schwarze Schüsseln eine rein auftragsbasierte Planung möglich war. Aus der vorherigen getrennten Analyse ist allerdings bekannt, dass dies für schwarze Schüsseln nicht angemessen ist, da diese im vierten Wertschöpfungsschritt eine längere Durchlaufzeit als rote Produkte hatten und entsprechend früher mit der Ausführung begonnen werden musste, um eine pünktliche Auslieferung zu gewährleisten.

Wie dieses Beispiel verdeutlicht und bereits von Hoekstra und Romme (1991, S. 8 ff.) erläutert wurde, ist die Betrachtung einer konsistenten Aggregationsebene Voraussetzung für die korrekte Bestimmung des Entkopplungspunkts. Es kann natürlich für eine Planungsaufgabe wichtig sein, den Entkopplungspunkt für eine Aggregationsebene zu bestimmen, die nach dem Kriterienkatalog von Hoekstra und Romme (1991, S. 111 ff.) nicht konsistent ist. Es kann beispielsweise sein, dass die Aggregationsebene verschiedene Produkte enthält, für die sich die Durchlaufzeiten bei einem Wertschöpfungsschritt stark unterscheiden. Um für diese Aggregationsebene trotzdem den Entkopplungspunkt zu bestimmen, müssen die darin enthaltenen Bestellungen auf mehrere granulare Aggregationsebenen aufgeteilt werden, die entsprechend des Kriterienkatalogs von Hoekstra und Romme (1991, S. 111 ff.) konsistent sind. Der Entkopplungspunkt kann anschließend für jede dieser granularen Aggregationsebenen separat ermittelt werden. Soll beispielsweise beim Porzellanhersteller der Entkopplungspunkt für alle Tassen untersucht werden, muss dieser für blaue, rote und schwarze Tassen jeweils einzeln und für gelbe und grüne Tassen gemeinsam analysiert werden. Nur auf diese Weise können unterschiedliche Planungsgrundlagen in Abhängigkeit von der Produktfarbe herausgearbeitet und fehlerhafte Schlussfolgerungen verhindert werden.

Wie bereits zum Abschluss des letzten Abschnitts erwähnt, beruht das beschriebene Verfahren auf den gemessenen durchschnittlich verbleibenden Durchlauf- bzw. Lieferzeiten. Eine Streuung dieser Zeiten wird dabei allerdings nicht beachtet. Ein wesentlicher Grund für diese Konzentration auf die Durchschnittswerte ist der Aufwand, der mit der Erfassung der Streuungswerte häufig verbunden ist. In einigen Supply Chains ist eine Erfassung der Streuung von verbleibender Durchlauf- bzw. Lieferzeit sehr aufwendig. Es muss allerdings erwähnt werden, dass diese Streuung Einfluss auf die Entkopplungspunktposition und die Planungsgrundlage für verschiedene Wertschöpfungsschritte haben kann.

Dieser Einfluss wird hier abschließend exemplarisch beschrieben. Es wird dafür eine Supply Chain betrachtet, die ihre Wertschöpfungskette auf die unterschiedlichen Vorlaufzeiten der Bestellungen ihrer Kunden abstimmt. Die Durchlaufzeiten eines Wertschöpfungsschritts können deshalb bei unterschiedlichen Durchführungen sehr stark schwanken. Die Ausführung des gleichen Schritts kann in Abhängigkeit von der Vorlaufzeit einer Bestellung einmal eine Stunde und beim nächsten Mal fünf Stunden in Anspruch nehmen. In Abbildung 6.11 sind zwei solche Situationen mit unterschiedlichen Durchlaufzeiten bei den letzten drei Schritten der Wertschöpfungskette dargestellt. In der ersten Situation dauert die Durchführung aller drei Schritte deutlich länger als in der zweiten Situation. In beiden Situationen beginnt die Supply Chain allerdings erst nach dem Bestellsingang mit der Ausführung des drittletzten Schritts. Die Schritte können also in beiden Situationen rein auftragsbasiert geplant werden. Dies mag sogar notwendig sein, weil die Supply Chain Informationen zu spezifischen Kundenwünschen aus der Bestellung für die Fertigung in diesen Schritten benötigt.

Werden allerdings die Durchschnittswerte betrachtet, so ergibt sich ein anderes Bild. Es ist in Abbildung 6.11 unten dargestellt. Die durchschnittlich verbleibende Lieferzeit für die drei letzten Schritte wird irgendwo zwischen den beiden Extremen aus den darüber aufgeführten Situationen liegen. Die anteilig vorliegende Bestellmenge zur entsprechenden Vorlaufzeit wird größer als 0% sein, da in Situation 1 der Auftrag früher eingegangen ist. Sie wird allerdings auch kleiner als 100% sein, da die Bestellung in Situation 2 erst später vorliegt. Die Schlussfolgerung hieraus wird sein, dass für den drittletzten Schritt eine Kombination aus auftrags- und prognosebasierter Planung durchzuführen ist, obwohl immer rein auftragsbasiert geplant wird.

Diese Fehleinschätzung ist auf die Nichtbeachtung der Streuung in den Durchlaufzeiten zurückzuführen. Insbesondere wenn Durchlauf- bzw. Lieferzeiten auf die Kundenwünsche und die damit verbundenen unterschiedlichen Vorlaufzeiten abgestimmt werden, sind hier größere Streuungswerte zu erwarten. Wenn es einer Supply Chain möglich ist, diese Streuungswerte zu berechnen, ist es durchaus angebracht, diese in die Bestimmung des Entkopplungspunkts einzubeziehen. Sollte es ihr nicht möglich sein, sollte sie sich allerdings der möglichen Implikationen für die Bestimmung des Entkopplungspunkts bewusst sein.




Abbildung 6.11.: Streuung von Durchlauf- und Lieferzeiten

6.4. Zusammenfassung

In diesem Kapitel wurde erstmals ein Verfahren vorgestellt, das es erlaubt, den Entkopplungspunkt in einer Wertschöpfungskette ex-post zu messen. Die betrachtete Ausgangssituation sowie der Einfluss der ADI auf den Entkopplungspunkt wurden zunächst in Abschnitt 6.1 erläutert. Es wurde dabei auch die Bedeutung des sukzessiven Bestellschritts für den Entkopplungspunkt erklärt.

Das Verfahren basiert neben dem in Kapitel 3 eingeführten verallgemeinerten Auftragsprofil und den Kennzahlen zur Charakterisierung des Bestellverhaltens aus Kapitel 5 auf den ex-post erfassten Durchlaufzeiten der unterschiedlichen Wertschöpfungsschritte. Die zu erfassenden Durchlauf- und Lieferzeiten werden in Abschnitt 6.2 beschrieben. Dabei wird die Vorgehensweise zur Erfassung dieser Werte detailliert erläutert. In diesem Zusammenhang wird auch die Bedeutung unterschiedlicher Aggregationsebenen sowie verschiedener Rüstkfamilien erklärt.

Das eigentliche Verfahren zur Bestimmung des Entkopplungspunkts, das auf einem Abgleich des Bestellverhaltens mit den Durchlaufzeiten bestimmter Wertschöpfungsschritte basiert, wird schließlich in Abschnitt 6.3 eingeführt. Jeder Schritt des Verfahrens wird dabei an einem Beispiel aus der Porzellanherstellung demonstriert.

Das beschriebene Verfahren erlaubt es einer Supply Chain, erstmals den Entkopplungspunkt in seiner Wertschöpfungskette ex-post zu messen. Die hieraus resultierenden Informationen sind für eine Supply Chain bei der Analyse und Optimierung der Planungsprozesse von immenser Bedeutung. Sie kann jetzt erstmals ermitteln, ob die verwendeten Planungsgrundlagen auch die richtigen sind. Wird beispielsweise ein Wertschöpfungsschritt rein auftragsbasiert geplant, obwohl die Analyse nach den Verfahren aus diesem Kapitel den Rückschluss zulässt, dass eine Kombination aus Aufträgen und Prognosen dafür verwendet werden muss, dann wird die Supply Chain eine zu geringe Menge fertigen, um die tatsächliche Nachfrage zum Wunschlieferzeitpunkt zu bedienen. Die noch ausstehende Bestellmenge hätte durch eine Prognose berücksichtigt werden müssen, damit genügend Produkte für die tatsächliche Nachfrage hergestellt worden wären. Die Supply Chain wird diesen Wertschöpfungsschritt nach dem Eingang der ausstehenden Bestellmengen kurzfristig ein weiteres Mal ausführen müssen, um eine Auslieferung aller Aufträge zu dem Wunschlieferzeitpunkt zu ermöglichen. Den damit verbundenen Aufwand inklusive der erneuten Rüstzeit hätte sie einsparen können, wenn sie durch die Kombination der vorliegenden Aufträge mit einer Prognose bereits bei der ersten Ausführung ausreichend Produkte hergestellt hätte. Die Identifikation solcher Missstände ist eine wichtige Grundlage für die Optimierung und mögliche Repositionierung des Entkopplungspunkts im Rahmen des Strategic Network Designs.

Mit dem hier vorgestellten Verfahren kann eine Supply Chain Wertschöpfungsschritte identifizieren, für die als Planungsgrundlage eine Kombination aus Aufträgen und Prognosen geeignet ist. Die in den beiden folgenden Kapiteln intensiv analysierten ADI-basierten Prognosemethoden erlauben es, Aufträge und Prognosen bei der Ermittlung der zu fertigenden Menge entsprechend zu kombinieren.

7. Analyse von Prognosemethoden mit Verwendung von Advanced Demand Information

Die Prognose zukünftiger Nachfrage ist eine wichtige Aufgabe in der Supply Chain-Planung. Wie in Kapitel 2 detailliert erläutert, wird die Vorhersage für die unterschiedlichsten Planungsaufgaben benötigt und ist somit für eine Supply Chain von großer Bedeutung. Ungenaue Prognosen haben entsprechend einen großen Einfluss auf den Erfolg bzw. Misserfolg der Supply Chain. Zahlreiche statistische Prognosemethoden sind deshalb entwickelt worden, um die künftige Nachfrage möglichst genau vorherzusagen. Elias u.a. (2006) präsentieren eine Übersicht aktueller statistischer Prognosemethoden. Wie bereits in der Einführung in den Kapiteln 1 und 2 angekündigt, gibt es einige statistische Prognosemethoden, die für die Vorhersage auf die ADI zurückgreifen.

Haberleitner u.a. (2010) haben einige dieser Methoden in einem Unternehmen für feuerfeste Materialien eingesetzt und getestet. Die Methoden liefern in bestimmten Situationen bessere Resultate als einige konventionelle Prognosemethoden. Sie erkennen beispielsweise Umsatzeinbrüche eher, da sie den Bestellrückgang berücksichtigen, der den Einbruch frühzeitig ankündigt. Sie liefern allerdings nicht ausnahmslos gute Prognoseergebnisse.

Da diese Methoden aber auch teilweise sehr genaue Vorhersagen liefern, soll in diesem Kapitel analysiert werden, unter welchen Gegebenheiten eine hohe Prognosegenauigkeit zu erwarten ist. Dies ist vor allem vor dem Hintergrund wichtig, dass mit der Implementierung der Methoden in einem APS ein signifikanter Zeitaufwand verbunden ist. Wie Haberleitner u.a. (2010) darlegen, gibt es bisher leider keine standardisierten Software-Module, die eine Implementierung der ADI-basierten Methoden enthalten. Es ist entsprechend notwendig, der Anwendung der ADI-basierten Prognosemethoden ein Projekt zu deren Implementierung in einem APS vorzuschalten. Es soll mit dieser Analyse entsprechend ermöglicht werden, vorab einzuschätzen, ob der Einsatz und damit die Implementierung dieser Prognosemethoden für eine Supply Chain geeignet sind.

Bevor mit der eigentlichen Analyse der Methoden begonnen wird, müssen in Abschnitt 7.1 noch einige wichtige Aspekte statistischer Prognosemethoden erläutert werden. Die eigentlichen Methoden werden in Abschnitt 7.2 vorgestellt. Eine analytische Auseinandersetzung mit den Methoden folgt in Abschnitt 7.3. Hier werden auch Treiber für die zu erwartende Genauigkeit der Prognosen identifiziert. Anschließend werden in Abschnitt 7.4 diese Treiber mit den charakterisierenden Kennzahlen für das Bestellverhalten aus Kapitel 5 verglichen. Der Einfluss der Kennzahlen auf die ADI-basierten Prognosemethoden, die Prognosequalität und damit auch implizit auf den Erfolg der Supply Chain




Abbildung 7.1.: Visualisierung der Idee der zeitreihenbasierten Prognose

wird hier detailliert beschrieben.

7.1. Wichtige Aspekte statistischer Prognosemethoden

Statistische Prognosemethoden verwenden ex-post vorliegende Daten und Informationen, um zukünftige Werte vorherzusagen. Der Fokus liegt hier auf der Prognose zukünftiger Nachfrage, auch wenn die Methoden zur Vorhersage anderer Werte eingesetzt werden können. Viele Prognosemethoden basieren auf den Ideen der bereits in Kapitel 4 vorgestellten Zeitreihen- und Regressionsanalyse.

Die Annahme, auf der die zeitreihenbasierte Prognose basiert, ist in Abbildung 7.1 illustriert.¹ Die schwarzen Punkte markieren die Nachfragewerte in der Vergangenheit und Zukunft. Die senkrechte Linie in der Mitte markiert die Gegenwart, also den Zeitpunkt, zu dem die Prognose erstellt wird. Auf Grundlage der zu diesem Zeitpunkt vorliegenden Vergangenheitswerte wird ein Zeitreihenmodell berechnet. In Abbildung 7.1 wurde exemplarisch ein Zeitreihenmodell mit Trend gewählt.² Das resultierende Modell wird nun einfach in die Zukunft extrapoliert, um zukünftige Werte zu prognostizieren. In der Abbildung repräsentiert die durchgezogene Linie das ex-post berechnete Zeitreihenmodell, während die gestrichelte Linie die Projektion in die Zukunft markiert. Bei zeitreihenbasierten Prognosemethoden wird also implizit die Annahme getroffen, dass das Zeitreihenmodell, das für die Beschreibung der ex-post vorliegenden Werte geeignet ist, auch für die Darstellung zukünftiger Werte passend ist.

Eine ähnliche Annahme wird für Prognosen auf Grundlage einer Regressionsanalyse getroffen. Die Beziehung zwischen unabhängigen Parameterwerten und abhängigem Pro-

¹Zu den Annahmen von Prognosen, die auf der Zeitreihen- oder Regressionsanalyse basieren, vgl. u.a. Ramanathan (2002, S. 494–527), Kilger und Wagner (2008) sowie Meyr (2012).

²Dieses und andere Zeitreihenmodelle wurden in Kapitel 4 vorgestellt und die dazugehörigen Berechnungsverfahren erläutert.

gnosewert wird ex-post auf Basis der vorliegenden Daten abgeschätzt. Nach Ermittlung der Ausprägungen der unabhängigen Werte kann die Regressionsgleichung genutzt werden, um den abhängigen Wert zu prognostizieren. Es wird dabei die Annahme getroffen, dass die für die Vergangenheitswerte ermittelte Regressionsgleichung auch in der Zukunft für die Beschreibung des Zusammenhangs zwischen unabhängigen Werten und abhängigem Wert geeignet ist. Der Einsatz der Regressionsanalyse kann nützlich sein, wenn die unabhängigen Werte zum Zeitpunkt der Prognose bereits bekannt sind oder sich besser vorhersagen lassen als der abhängige Wert.

Neben den bereits in Kapitel 4 aufgeführten Arbeiten und Methoden enthält die Veröffentlichung von Elias u.a. (2006) eine Übersicht aktueller Prognosemethoden basierend auf der Zeitreihen- und Regressionsanalyse, die unter anderem auch die Methoden von Box u.a. (2008) umfasst. Auf eine detaillierte Darstellung dieser Methoden wird unter Verweis auf diese Veröffentlichungen hier verzichtet.

Für die weitere Erläuterung der statistischen Prognosemethoden werden zusätzliche Variablen benötigt.

Zur Beschreibung einer beliebigen Prognose wird nun folgende Variable verwendet:

DF_{Aes} Prognose erstellt mit einer Vorlaufzeit e für die zukünftige Nachfrage zum Zeitpunkt s auf der Aggregationsebene A .

Da eine Prognose nicht immer mit der später beobachteten tatsächlichen Nachfrage übereinstimmt, verbleibt ein sogenannter Prognosefehler, der der Differenz zwischen prognostizierter und tatsächlicher Nachfrage entspricht.

EA_{Aes} Absoluter Prognosefehler der mit einer Vorlaufzeit e erstellten Prognose, die sich auf die zukünftige Nachfrage zum Zeitpunkt s und die Aggregationsebene A bezieht. Es gilt $EA_{Aes} = D_{A0s} - DF_{Aes}$.

Zusätzlich beschreibt folgende Variable den relativen Prognosefehler in Bezug auf die tatsächliche Nachfrage:

ER_{Aes} Relativer Prognosefehler der mit einer Vorlaufzeit e erstellten Prognose, die sich auf die zukünftige Nachfrage zum Zeitpunkt s und die Aggregationsebene A bezieht. Es gilt $ER_{Aes} = EA_{Aes}/D_{A0s}$. Der relative Prognosefehler ist nur definiert, wenn die Nachfrage $D_{A0s} > 0$ ist.

Die arithmetischen Mittel, Standardabweichungen und Variationskoeffizienten gelten analog zu den Definitionen für die Bestellmengen in Kapitel 3 auch für die Prognosen und Prognosefehler. So repräsentiert $\mu(t_1, t_n, EA_{Aes})$ beispielsweise den durchschnittlichen absoluten Prognosefehler auf der Aggregationsebene A , der bei den Prognosen für die Zeitpunkte zwischen t_1 und t_n mit einer Vorlaufzeit von e zu beobachten ist. Es gilt $\mu(t_1, t_n, EA_{Aes}) = \sum_{s=t_1}^{t_n} EA_{Aes}/n$.

Tempelmeier (2008, S. 33–36) unterscheidet zwei Eigenschaften des Prognosefehlers:

1. Das Niveau des Prognosefehlers
2. Die Streuung des Prognosefehlers

Das Niveau beschreibt eine Systematik des Prognosefehlers. Ein systematischer Fehler tritt bei der Wahl eines ungeeigneten Modells zur Abbildung der Zeitreihe auf. Wird beispielsweise das Zeitreihenmodell konstanter Nachfrage gewählt, obwohl ein Trend vorliegt, wird das resultierende Modell die zukünftigen Werte systematisch über- bzw. unterschätzen. Diese Situation ist exemplarisch in Abbildung 7.2 illustriert. Es ist die gleiche Zeitreihe wie in Abbildung 7.1 aufgeführt. Die Prognose der zukünftigen Nachfrage, dargestellt durch die gestrichelte Linie, unterschätzt die tatsächliche Nachfrage hier allerdings, weil der positive Trend in der Zeitreihe von dem Modell nicht berücksichtigt wird. Wie Tempelmeier (2008, S. 33–36) konstatiert, ist bei Fehlen eines systematischen Prognosefehlers dessen Erwartungswert null. Ein positiver bzw. negativer Erwartungswert impliziert dabei, dass die Prognose im Durchschnitt systematisch zu niedrig oder zu hoch angesetzt ist. Entsprechend ist das arithmetische Mittel der Prognosefehler in Abbildung 7.2 positiv, da die Prognose die tatsächliche Nachfrage immer unterschätzt.




Abbildung 7.2.: Systematische Fehleinschätzung durch Nachfrageprognose

Um zu überprüfen, ob der Erwartungswert null sein kann, wird unter anderem von Bleymüller u.a. (2002, S. 107–108) sowie McClave u.a. (2005, S. 419–424) ein Test beschrieben, der auf der Standardnormalverteilung beruht. Als Testgröße wird hier $T = \sqrt{n} \cdot \mu(t_1, t_n, EA_{Aes}) / \sigma(t_1, t_n, EA_{Aes})$ benutzt. Gilt $-g \leq T \leq g$ ist die Hypothese, dass es keinen systematischen Fehler gibt, nicht zu verwerfen. Wenn allerdings $|T| > g$, ist die Hypothese abzulehnen und es liegt vermutlich ein systematischer Fehler vor. Dabei entspricht g dem Wert, den eine Standardnormalverteilung mit einer Wahrscheinlichkeit von $1 - \alpha/2$ nicht überschreitet.³ α entspricht dem durch den Nutzer zu bestimmten Signifikanzniveau.⁴ Damit der Test funktioniert, muss die betrachtete Stichprobe von Prognosefehlern einen gewissen Umfang haben. McClave u.a. (2005, S. 419–424) ge-

³Mit den verbreiteten Tabellen zur Standardnormalverteilung – vgl. beispielsweise Pearson und Hartley (1976a, S. 110–116) sowie Pearson und Hartley (1976b, S. 153–155) – kann g einfach ermittelt werden.

⁴Die in Kapitel 4 erläuterte Autokorrelation und Heteroskedastizität beschreiben ebenfalls eine Systematik des Prognosefehlers. Sie können auch dann vorliegen, wenn der Erwartungswert der Prognosefehler null ist. Das Vorliegen eines solchen Fehlers kann mit den ebenfalls in Kapitel 4 aufgezählten

ben in diesem Zusammenhang an, dass die Stichprobe für den Test mindestens $n \geq 30$ Ausprägungen von Prognosefehlern enthalten muss.

Der verbleibende nicht systematische Prognosefehler wird als Streuung bezeichnet. Da dieser Fehler keiner Systematik unterliegt, tritt er zufällig auf und ist identisch unabhängig verteilt. Er entspricht dem Prognosefehler, der bei Verwendung eines Zeitreihenmodells ohne systematische Fehleinschätzung auftritt. Die Prognosefehler in Abbildung 7.1 resultieren aus dieser Streuung.

Es ist wichtig zu erwähnen, dass ein systematischer Fehler meist durch den Nutzer und die Wahl des falschen Prognosemodells bedingt ist. Die Streuung hingegen ist zufällig und kann entsprechend vom Nutzer nicht beeinflusst werden.

Zur Bewertung der Prognosegenauigkeit werden häufig statistische Kriterien und in diesem Zusammenhang oft Standardmaße verwendet. Drei häufig benutzte Standardmaße sind der *mean square error* (MSE), der erstmals bereits in Kapitel 4 erläutert wurde, die *mean absolute deviation* (MAD) sowie der *mean absolute percentage error* (MAPE).⁵ An dieser Stelle werden die Standardmaße für eine Aggregationsebene A und Vorlaufzeit e in den Formeln 7.1.1 bis 7.1.3 definiert. Für die m Prognosen mit einer Vorlaufzeit von e , die zu den Zeitpunkten t_n bis $t_n + (m - 1)$ für die zukünftigen Zeitpunkte $t_n + e$ bis $t_n + (m - 1) + e$ erstellt werden, gilt dann:

$$MSE_{Ae} = \frac{1}{m} \sum_{s=t_n+e}^{t_n+(m-1)+e} (EA_{Aes})^2 \quad (7.1.1)$$

$$MAD_{Ae} = \frac{1}{m} \sum_{s=t_n+e}^{t_n+(m-1)+e} |EA_{Aes}| \quad (7.1.2)$$

$$MAPE_{Ae} = \frac{1}{m} \sum_{s=t_n+e}^{t_n+(m-1)+e} |ER_{Aes}| \quad (7.1.3)$$

Der MSE gibt den durchschnittlichen quadrierten absoluten Prognosefehler an. MAD und MAPE messen den durchschnittlichen Betrag des absoluten bzw. relativen Prognosefehlers. Die Maße müssen allerdings nicht zwangsläufig für eine bestimmte Aggregationsebene und Vorlaufzeit definiert werden. Bei Kilger und Wagner (2008) werden die Maße beispielsweise zum Zeitpunkt s für Prognosen mit Vorlaufzeiten zwischen 1 und n auf der Aggregationsebene A angegeben. Der MSE hat dann folgende Form: $MSE_{As} = \frac{1}{n} \sum_{e=1}^n (EA_{Ae(s+e)})^2$. In dieser Arbeit wird aber die Definition aus den For-

Tests überprüft werden. Die Autokorrelation oder Heteroskedastizität kann gegebenenfalls durch die Wahl eines anderen Prognosemodells eliminiert werden.

⁵Zu den Standardmaßen vgl. beispielsweise Kilger und Wagner (2008) oder Ramanathan (2002, S. 112–113). Die *mean absolute percentage accuracy* (MAPA) wird hier nicht betrachtet, da sie nicht den Fehler, sondern umgekehrt die Präzision misst.

meln 7.1.1 bis 7.1.3 verwendet, außer es wird explizit auf die Nutzung einer anderen Variante hingewiesen.

7.2. Vorstellung verschiedener Prognosemethoden

In der Zeitreihen- und Regressionsanalyse wurden zahlreiche Prognosemodelle entwickelt. Der Fokus der folgenden Analysen liegt auf Methoden, die die ADI benutzen. Sie werden dabei mit zwei klassischen Methoden der Zeitreihenanalyse verglichen: Dem Modell konstanter Nachfrage und dem Zeitreihenmodell, das einen Trend berücksichtigt. Die beiden klassischen Methoden werden zunächst in Abschnitt 7.2.1 definiert. Anschließend folgt in Abschnitt 7.2.2 ein umfassender Überblick über statistische Prognosemethoden, die die ADI einsetzen.

In den bisherigen Ausführungen wurden tatsächliche Werte betrachtet, in diesem Abschnitt kommen nun Schätzwerte dazu. Ein Schätzwert ist dabei durch ein $\hat{\cdot}$ markiert. Wenn also $E(D_{A0t_n})$ den tatsächlichen Erwartungswert der Nachfrage repräsentiert, so ist $\hat{E}(D_{A0t_n})$ der dazugehörige Schätzwert. Analog ist $\hat{\sigma}(t_1, t_n, U_{Aes})$ ein Schätzwert für die Standardabweichung der zur Vorlaufzeit e ausstehenden Bestellmenge auf der Aggregat ionsebene A mit Wunschlief erzeitpunkt s im Zeitraum zwischen t_1 und t_n . $\sigma(t_1, t_n, U_{Aes})$ ist die entsprechende tatsächliche Standardabweichung.

7.2.1. Prognosemethoden aus der klassischen Zeitreihenanalyse

Die in diesem Abschnitt beschriebenen Methoden werden auch in zahlreichen anderen statistischen Veröffentlichungen erläutert. Exemplarisch seien hier Silver u.a. (1998, S. 74 ff.), Tempelmeier (2008, S. 40 ff.) sowie Meyr (2012) genannt.

Das einfachste Modell in der Zeitreihenanalyse ist das einer konstanten Nachfrage. Wenn dieses Modell zur Prognose der zukünftigen Nachfrage verwendet wird, ist die implizite Annahme, dass der Durchschnittswert der vorliegenden Vergangenheitswerte auch zukünftig der im Schnitt zu erwartenden Nachfrage entspricht. Wenn der Durchschnittswert durch das arithmetische Mittel berechnet wird, gilt $\hat{E}(D_{A0t_n}) = \mu(t_1, t_n, D_{A0s})$. Das arithmetische Mittel dient also zum aktuellen Zeitpunkt t_n als Schätzer $\hat{E}(D_{A0t_n})$ für den tatsächlichen Erwartungswert der Nachfrage $E(D_{A0t_n})$. Dieser Schätzer des Erwartungswertes wird nun als Prognosewert der zukünftigen Nachfrage verwendet. Die Methode hat für eine Prognose mit der beliebigen Vorlaufzeit $e = 1, 2, \dots$ folgende Form:

$$DF_{Ae(t_n+e)} = \hat{E}(D_{A0t_n}) = \mu(t_1, t_n, D_{A0s}) \quad (7.2.1)$$

Das Vorgehen ist bei der Verwendung des Zeitreihenmodells mit Trend ähnlich. Mit den in Kapitel 4 vorgestellten Formeln kann der y-Achsenabschnitt β_0 und die Steigung der Trendgeraden β_1 ex-post für die vorliegenden Vergangenheitswerte berechnet werden. Es wird nun die Annahme getroffen, dass sich diese Werte für den zu prognostizierenden Zeitraum nicht verändern. Die ermittelten Werte β_0 und β_1 werden also als Schätzer $\hat{\beta}_0$ und $\hat{\beta}_1$ zur Prognose der zukünftigen Werte eingesetzt. Für eine beliebige Vorlaufzeit e

hat die Prognosemethode entsprechend folgende Form:

$$DF_{Ae(t_n+e)} = \hat{\beta}_0 + \hat{\beta}_1 \cdot (t_n + e) = \beta_0 + \beta_1 \cdot (t_n + e) \quad (7.2.2)$$

Die beiden in Gleichung 7.2.1 und 7.2.2 vorgestellten Prognosemethoden verwenden das arithmetische Mittel bzw. die Formeln zur Berechnung einer Trendgerade aus Kapitel 4 als Schätzer der zukünftigen Werte. Wie ebenfalls in Kapitel 4 beschrieben, minimieren diese Berechnungsverfahren den MSE bei den vorliegenden Vergangenheitswerten. Dies ist ein guter Grund, sie auch als Schätzer der zukünftigen Werte zu benutzen. Es gibt allerdings auch Alternativen. Statt des arithmetischen Mittels kann beispielsweise auch ein gewichteter Mittelwert verwendet werden, der aktuelle Nachfragewerte stärker einbezieht als ältere. Das geometrische Mittel ist eine weitere Alternative zum arithmetischen. Nach der initialen Nutzung einer Prognosemethode ist es auch möglich, die Werte für zukünftige Prognosen mit den in Kapitel 4 erläuterten Formeln exponentiell zu glätten. Das geeignete Schätzverfahren ist situationsabhängig vom Anwender zu wählen.

Es wird nun das Beispiel aus Tabelle 5.13 benutzt, um den Einsatz der Prognosemethoden zu demonstrieren. Tabelle 7.1 enthält die tatsächlichen Nachfragewerte D_{A0s} für dieses Beispiel. Die Nachfrage für die Zeitpunkte t_{13} bis t_{16} wird mit einer Vorlaufzeit von $e = 1$ prognostiziert. Dabei werden die Schätzer der beiden Methoden jeweils auf Basis der letzten 12 Zeitpunkte berechnet.⁶

Die Prognose $DF_{A1t_{14}}$ wird also zum Zeitpunkt t_{13} erstellt, wobei die Nachfragewerte D_{A0t_2} bis $D_{A0t_{13}}$ für die Schätzer berücksichtigt werden. Das entsprechende arithmetische Mittel $\mu(t_2, t_{13}, D_{A0s})$ zum Zeitpunkt t_{13} beträgt 104,58. Mit dem Modell einer konstanten Nachfrage ist die Vorhersage für t_{14} dann ebenfalls 104,58. Bei Verwendung eines Zeitreihenmodells mit Trend ergeben sich die folgenden Schätzer zu diesem Zeitpunkt: $\hat{\beta}_0 = 99,73$ und $\hat{\beta}_1 = 0,6469$. Daraus resultiert dann wiederum folgende Prognose für t_{14} : $DF_{A1t_{14}} = 99,73 + 0,6469 \cdot 14 = 108,79$. Diese Schätzer und Prognosen sowie die für die anderen drei Zeitpunkte sind ebenfalls in Tabelle 7.1 aufgeführt.

⁶Der Schätzer für die in Gleichung 7.2.1 dargestellte Methode entspricht damit dem gleitenden Durchschnitt über die letzten 12 Zeitpunkte.

7. Analyse von Prognosemethoden mit Verwendung von Advanced Demand Information

D_{A0s}	<i>Wunschlieferzeitpunkt</i>											
	t_1	t_2	t_3	t_4	t_5	t_6	t_7	t_8	t_9	t_{10}	t_{11}	t_{12}
	100	105	95	105	100	105	110	100	105	105	115	100
	t_{13}	t_{14}	t_{15}	t_{16}								
	110	110	125	120								
<i>Schätzer für Prognosemethoden</i>												
Zeitpunkt der Schätzung t_x					t_{12}	t_{13}	t_{14}	t_{15}				
$\mu(t_{x-11}, t_x, D_{A0s})$					103,75	104,58	105,00	107,50				
β_0					100,00	99,73	97,57	96,21				
β_1					0,5769	0,6469	0,8741	1,1888				
<i>Prognosen DF_{A1t_x}</i>												
Prognostizierter Zeitpunkt t_x					t_{13}	t_{14}	t_{15}	t_{16}				
Konstante Nachfrage					103,75	104,58	105,00	107,50				
Zeitreihe mit Trend					107,50	108,79	110,68	115,23				

Tabelle 7.1.: Beispielhafte Nutzung der Prognosemethoden aus der klassischen Zeitreihenanalyse

Tabelle 7.2 enthält die resultierenden Prognosefehler. Zusätzlich sind die Standardmaße MSE, MAD und MAPE berechnet worden. Die Methode, die den positiven Trend der Zeitreihe berücksichtigt, weist durchgängig genauere Prognosen auf. Die drei Standardmaße sind für dieses Modell entsprechend niedriger. Allerdings unterschätzt auch dieses Modell die tatsächliche Nachfrage systematisch. Die durchgängig positiven Prognosefehler zeigen dies deutlich.

<i>Absolute Prognosefehler EA_{A1t_x}</i>				
Prognostizierter Zeitpunkt t_x	t_{13}	t_{14}	t_{15}	t_{16}
Konstante Nachfrage	6,25	5,42	20,00	12,50
Zeitreihe mit Trend	2,50	1,21	14,32	4,77
<i>Relative Prognosefehler ER_{A1t_x}</i>				
Prognostizierter Zeitpunkt t_x	t_{13}	t_{14}	t_{15}	t_{16}
Konstante Nachfrage	5,68%	4,92%	16,00%	10,42%
Zeitreihe mit Trend	2,27%	1,10%	11,45%	3,98%
Standardmaße		MSE_{A1}	MAD_{A1}	$MAPE_{A1}$
Konstante Nachfrage		156,16	11,04	9,26%
Zeitreihe mit Trend		58,88	5,70	4,70%

Tabelle 7.2.: Prognosefehler aus beispielhafter Verwendung der Prognosemethoden




Abbildung 7.3.: Ideengrundlage unterschiedlicher ADI-basierter Prognosemethoden

7.2.2. Advanced Demand Information verwendende Prognosemethoden

Drei wesentliche Typen von einfachen ADI-basierten Prognosemethoden zur Vorhersage zukünftiger Nachfrage sind zu unterscheiden:

1. Multiplikative Methoden
2. Additive Methoden
3. Hybride Methoden

Die multiplikative Methode wurde unter anderem von Bestwick (1975) sowie Bodily und Freeland (1988) beschrieben. Die additive und hybride Methode wurden von Kekre u.a. (1990) eingeführt. Die verschiedenen den Methoden zugrunde liegenden Ideen sind in Abbildung 7.3 illustriert. Die vorliegende durch eine Raute markierte ADI wird auf unterschiedliche Weise zur Prognose der künftigen Nachfrage eingesetzt.

Die multiplikative Methode versucht den Anteil abzuschätzen, den die kumuliert vorliegende Bestellmenge bei einer Vorlaufzeit von e an der tatsächlichen Nachfrage hat. Geschätzt werden soll also der Erwartungswert $E(X_{Aet_n})$ der zur Vorlaufzeit e anteilig vorliegenden Bestellmenge. Der entsprechende Schätzer ist $\hat{E}(X_{Aet_n})$. Die Methode skaliert die kumuliert vorliegende Bestellmenge durch die Division mit diesem geschätzten Erwartungswert hoch und prognostiziert so die tatsächliche Nachfrage. Die Methode hat entsprechend folgende in Gleichung 7.2.3 aufgeführte Form:

$$DF_{Ae(t_n+e)} = D_{Ae(t_n+e)} / \hat{E}(X_{Aet_n}) \quad (7.2.3)$$

Das Prinzip, welches der additiven Methode zugrunde liegt, ist ein anderes. Diese Methode ist darauf fokussiert, die noch ausstehende Bestellmenge vorherzusagen. Die Bestellmenge, die mit einer Vorlaufzeit von e oder länger eingegangen ist, liegt durch die ADI

7. Analyse von Prognosemethoden mit Verwendung von Advanced Demand Information

bereits vor und wird als gegeben angesehen. Es muss nun abgeschätzt werden, welche Bestellmenge in der verbleibenden Zeit noch zu erwarten ist. Der Schätzer dieses Erwartungswerts der zu Vorlaufzeit e noch ausstehenden Bestellmenge ist $\hat{E}(U_{\text{Aet}_n})$. Dieser Wert ist mit der vorliegenden Bestellmenge zu summieren, um die Prognose abzuleiten. Die entsprechende Prognosegleichung lautet:

$$DF_{\text{Ae}(t_n+e)} = D_{\text{Ae}(t_n+e)} + \hat{E}(U_{\text{Aet}_n}) \quad (7.2.4)$$

Die hybride Methode basiert auf der Annahme, dass eine Korrelation zwischen der zur Vorlaufzeit e kumuliert vorliegenden Bestellmenge und der späteren Nachfrage besteht. Mit den Methoden der Regressionsanalyse aus Abschnitt 4.2 kann eine lineare Regression zwischen diesen Werten abgeschätzt werden. Dies umfasst einen Schätzwert für den y-Achsenabschnitt $\hat{\beta}_0(D_{\text{Aet}_n}, D_{\text{A0t}_n})$ und die Steigung der Trendgeraden $\hat{\beta}_1(D_{\text{Aet}_n}, D_{\text{A0t}_n})$. Die Prognosegleichung ist in Formel 7.2.5 dargestellt.

$$DF_{\text{Ae}(t_n+e)} = \hat{\beta}_0(D_{\text{Aet}_n}, D_{\text{A0t}_n}) + \hat{\beta}_1(D_{\text{Aet}_n}, D_{\text{A0t}_n}) \cdot D_{\text{Ae}(t_n+e)} \quad (7.2.5)$$

Wie bereits Kekre u.a. (1990) festgestellt haben, geht die additive Methode im Gegensatz zur multiplikativen und hybriden Prognosemethode nicht davon aus, dass es einen Zusammenhang zwischen den bereits vorliegenden und den noch ausstehenden Bestellungen gibt. $\hat{E}(U_{\text{Aet}_n})$ wird für die additive Methode üblicherweise ohne Berücksichtigung der vorliegenden Bestellmenge $D_{\text{Ae}(t_n+e)}$ geschätzt und anschließend damit summiert. In der multiplikativen und hybriden Prognosemethode wird der Schätzwert $\hat{E}(U_{\text{Aet}_n})$ nicht benötigt. Bei der multiplikativen Methode wird angenommen, dass das Verhältnis von kumuliert vorliegender und ausstehender Bestellmenge unverändert bleibt und somit $D_{\text{Ae}(t_n+e)}$ entsprechend skaliert werden kann. Die hybride Methode fundiert auf der Annahme, dass die kumuliert vorliegende Bestellmenge und die tatsächliche Nachfrage korrelieren. Da die tatsächliche Nachfrage der Summe aus kumuliert vorliegender und ausstehender Bestellmenge entspricht, impliziert die Annahme der hybriden Methode ebenfalls eine lineare Korrelation zwischen kumuliert vorliegender und ausstehender Bestellmenge. Die ausstehende Bestellmenge wird also bei der multiplikativen und hybriden Prognosemethode implizit in Abhängigkeit von der vorliegenden Menge abgeschätzt.

Kekre u.a. (1990) sowie Guerrero und Elizondo (1997) haben die multiplikative und additive Methode zusätzlich als Extremform der hybriden Prognosemethode beschrieben. Im ersten Fall gilt $\hat{\beta}_0(D_{\text{Aet}_n}, D_{\text{A0s}}) = 0$, während im zweiten Fall $\hat{\beta}_1(D_{\text{Aet}_n}, D_{\text{A0s}}) = 1$ ist. Kekre u.a. (1990) sowie Haberleitner u.a. (2010) zeigen, dass sich die ADI-basierten Methoden besonders bei plötzlichen starken Nachfrageveränderungen eignen. Ein Nachfrageeinbruch kündigt sich beispielsweise häufig frühzeitig durch einen Bestellungsrückgang an. Während die konventionellen Methoden diesen Rückgang in den Vorhersagen nicht reflektieren, wird er von den ADI-basierten Methoden berücksichtigt. Sie erkennen den Einbruch der tatsächlichen Nachfrage so früher als die konventionellen Methoden. Dieser Vorteil kann es einer Supply Chain ermöglichen, frühzeitiger auf starke Nachfrageverän-

derungen zu reagieren.

In den folgenden Abschnitten werden die unterschiedlichen veröffentlichten Varianten der multiplikativen (7.2.2.1), additiven (7.2.2.2) und hybriden (7.2.2.3) Methode detailliert vorgestellt. Ein wesentliches Unterscheidungsmerkmal ist dabei das jeweils eingesetzte Schätzverfahren zur Bestimmung der verschiedenen Erwartungswerte. Weitere Veröffentlichungen ADI-basierter Prognosemethoden werden in Abschnitt 7.2.2.4 kurz dargestellt. Dem Autor ist kein übergreifender Vergleich der Prognosequalität der verschiedenen Varianten bekannt.

7.2.2.1. Multiplikative Prognosemethode

Die in der Arbeit von Bestwick (1975) vorgestellte Prognosemethode entspricht exakt der zuvor in Abschnitt 7.2.2 aufgeführten Version der multiplikativen Prognosemethode. Als Schätzwert für $\hat{E}(X_{Aet_n})$ wird das arithmetische Mittel der anteilig vorliegenden Bestellmengen zu dieser Vorlaufzeit eingesetzt. Es gilt also $\hat{E}(X_{Aet_n}) = \mu(t_1, t_n, X_{Aes})$. Mit der Wahl des arithmetischen Mittels wird implizit die Annahme getroffen, dass die anteilig vorliegenden Bestellmengen zur Vorlaufzeit e in der Vergangenheit bis auf zufällige Abweichungen einer konstanten Zeitreihe entsprochen haben. Mit der Nutzung des arithmetischen Mittels als Schätzwert wird weiter angenommen, dass dies auch in der Zukunft so sein wird. Die implizite Hypothese dieses Schätzverfahrens ist, dass das prozentuale Verhältnis aus vorliegender Bestellmenge und tatsächlicher Nachfrage über die Zeit hinweg bis auf zufällige Abweichungen unverändert bleibt und entsprechend für die Prognose eingesetzt werden kann.

Bodily und Freeland (1988) stellen drei unterschiedliche Prognosemethoden vor. Zwei basieren auf den Ideen der multiplikativen Methode. Es werden jeweils zwei unterschiedliche Verfahren zur Bestimmung des Schätzwertes eingesetzt. Die erste Methode entspricht der bekannten von Bestwick (1975). In der ersten Variante wird auch das identische Schätzverfahren eingesetzt. In der alternativen Variante wird der Schätzwert nach seiner Initialisierung exponentiell geglättet. Auch diesem Verfahren liegt die Annahme zugrunde, dass die Zeitreihe der anteilig vorliegenden Bestellmenge in der Vergangenheit und Zukunft bis auf zufällige Abweichungen konstant ist. Die Formel für das alternative Schätzverfahren lautet:

$$\hat{E}(X_{Aet_n}) = \alpha \cdot X_{Aet_n} + (1 - \alpha) \cdot \hat{E}(X_{Ae(t_n-1)}) \quad (7.2.6)$$

Die resultierende Prognosemethode wird auch durch Gleichung 7.2.7 beschrieben:

$$DF_{Ae(t_n+e)} = \frac{D_{Ae(t_n+e)}}{\alpha \cdot X_{Aet_n} + (1 - \alpha) \cdot \hat{E}(X_{Ae(t_n-1)})} \quad (7.2.7)$$

Bodily und Freeland (1988) haben zusätzlich eine zweite Version der multiplikativen Methode eingeführt. Bei dieser wird für eine feste Vorlaufzeit die Prognose mit Voranschreiten der Zeit selbst exponentiell geglättet. In die Nachfragevorhersage $DF_{Ae(t_n+e)}$ mit Vorlaufzeit e für den Wunschliefzeitpunkt $t_n + e$ fließen so zwei Faktoren ein:

7. Analyse von Prognosemethoden mit Verwendung von Advanced Demand Information

1. Die Vorhersage $DF_{\mathbf{A}e(t_n+e-1)}$ für den Wunschlieferzeitpunkt $t_n + e - 1$, die ebenfalls mit einer Vorlaufzeit e erstellt wurde.
2. Die hochskalierte Bestellmenge $d_{\mathbf{A}e(t_n+e)}$, die exakt zur Vorlaufzeit e eingegangen ist.

Zur Skalierung von $d_{\mathbf{A}e(t_n+e)}$ wird dabei der erwartete Anteil dieser Bestellmenge an der tatsächlichen Nachfrage verwendet. Im Gegensatz zur bisher betrachteten kumuliert anteilig vorliegenden Bestellmenge $X_{\mathbf{A}e(t_n+e)}$ bezieht sich diese anteilige Bestellmenge $x_{\mathbf{A}e(t_n+e)}$ nur auf die aktuelle Vorlaufzeit. Es gilt $x_{\mathbf{A}e(t_n+e)} = d_{\mathbf{A}e(t_n+e)} / D_{\mathbf{A}0(t_n+e)}$. Der Schätzwert des erwarteten anteiligen Wertes ist $\hat{E}(x_{\mathbf{A}et_n})$. Er kann als einfaches arithmetisches Mittel der bekannten Vergangenheitswerte $x_{\mathbf{A}es}$ geschätzt werden:

$$\hat{E}(x_{\mathbf{A}et_n}) = \mu(t_1, t_n, x_{\mathbf{A}es}) \quad (7.2.8)$$

Alternativ kann auch dieser Schätzwert exponentiell geglättet werden:

$$\hat{E}(x_{\mathbf{A}et_n}) = \alpha \cdot x_{\mathbf{A}et_n} + (1 - \alpha) \cdot \hat{E}(x_{\mathbf{A}e(t_n-1)}) \quad (7.2.9)$$

Hochskaliert wird nun $d_{\mathbf{A}e(t_n+e)}$, indem die Bestellmenge durch $\hat{E}(x_{\mathbf{A}et_n})$ dividiert wird. Die resultierende Prognosemethode hat folgende Form:

$$DF_{\mathbf{A}e(t_n+e)} = \alpha \cdot d_{\mathbf{A}e(t_n+e)} / \hat{E}(x_{\mathbf{A}et_n}) + (1 - \alpha) \cdot DF_{\mathbf{A}e(t_n+e-1)} \quad (7.2.10)$$

Der Glättungsfaktor α ist durch den Anwender zu bestimmen. Durch die exponentielle Glättung von $DF_{\mathbf{A}e(t_n+e)}$ wird bei gegebener Vorlaufzeit eine Konstanz der Prognose selbst unterstellt. Insgesamt stellen Bodily und Freeland (1988) also zwei Varianten der multiplikativen Methode vor, die in den Gleichungen 7.2.3 und 7.2.10 beschrieben werden. Beide Varianten nutzen zur Berechnung des Schätzwertes entweder das arithmetische Mittel oder glätten diesen Wert selbst exponentiell. Der Einsatz der unterschiedlichen Varianten der multiplikativen Prognosemethode wird im Anhang in Abschnitt A.1 demonstriert. Es wird wieder das Beispiel aus Tabelle 5.13 benutzt.

Die dritte Methode von Bodily und Freeland (1988) ähnelt der additiven Methode, weshalb sie in Abschnitt 7.2.2.2 beschrieben wird. Im Zusammenhang mit der multiplikativen Methode müssen noch die Arbeiten von de Alba und Mendoza (2001) sowie Mendoza und de Alba (2006) erwähnt werden. Ihre Prognoseverfahren fundieren auf der multiplikativen Methode. Sie sollen sich besonders zur Abschätzung von Zeitreihen mit Saisonalität und nur wenigen Vergangenheitswerten eignen. Die Arbeiten enthalten mehrere Prognosemethoden, die teilweise durch den Anwender zu definierende Loss-Functions berücksichtigen. Diese Loss-Functions ermöglichen es dem Anwender, eine Über- bzw. Unterschätzung der tatsächlichen Nachfrage durch die Prognosemethode unterschiedlich zu bewerten und dies auch in der eigentlichen Prognose zu reflektieren. Das einfachste Verfahren entspricht der Methode von Bestwick (1975), wobei nicht das arithmetische sondern das geometrische Mittel für die Berechnung des Schätzers benutzt wird. Komplexere Varianten unter Einbezug der Loss-Functions verwenden für die Prognose unterschiedliche

Quantile der Häufigkeitsverteilung der Gesamtnachfrage und damit zusammenhängend verschiedene Potenzen des geometrischen Mittels. Einige Prognosemethoden betrachten auch das logarithmierte Verhältnis der noch ausstehenden zu den kumuliert vorliegenden Bestellungen: $\log(U_{\text{Aet}_n}/D_{\text{Aet}_n})$. In diesem Zusammenhang wird unter anderem auch die Student-t-Verteilung für die Schätzungen herangezogen. Weil diese komplexen Methoden im Anschluss nicht weiter analysiert werden, erfolgt an dieser Stelle keine detaillierte Darstellung der Methoden von de Alba und Mendoza (2001) sowie Mendoza und de Alba (2006).

7.2.2.2. Additive Prognosemethode

Die additive Methode, wie sie in Formel 7.2.4 beschrieben wird, wurde von Kekre u.a. (1990) eingeführt. Der Schätzwert $\hat{E}(U_{\text{Aet}_n})$ wird hier durch exponentielle Glättung der ausstehenden Bestellmenge ermittelt.

Wie bereits erwähnt, haben Bodily und Freeland (1988) eine Methode veröffentlicht, die der additiven ähnelt. Sie führen sie allerdings als Bayessche und nicht als additive Methode ein. Sie entspricht in der Form Gleichung 7.2.4, allerdings sind die Schätzverfahren für $\hat{E}(U_{\text{Aet}_n})$ deutlich aufwendiger. Unter anderem fließen hier auch die vorliegenden Bestellmengen mit ein, was der erwähnten Idee der additiven Prognosemethode widerspricht, dass die ausstehende Bestellmenge unabhängig von den vorliegenden Bestellungen abgeschätzt wird. Die Schätzverfahren werden hier nicht detailliert vorgestellt, da dies sehr aufwendig ist und auf sie im weiteren Verlauf der Arbeit nicht zurückgegriffen wird.

Weitere additive Prognosemethoden werden von Guerrero und Elizondo (1997) eingeführt. Neben der exponentiellen Glättung wie bei Kekre u.a. (1990) verwenden sie das arithmetische Mittel als Schätzer für $\hat{E}(U_{\text{Aet}_n})$. Es gilt also $\hat{E}(U_{\text{Aet}_n}) = \mu(t_1, t_n, U_{\text{Aes}})$. Dabei wird mit der Wahl des arithmetischen Mittels implizit die Annahme getroffen, dass die ausstehenden Bestellmengen zur Vorlaufzeit e in der Vergangenheit einer konstanten Zeitreihe entsprochen haben. Gleichzeitig wird mit der Nutzung des arithmetischen Mittels als Schätzwert angenommen, dass dies auch in der Zukunft so sein wird.⁷ Die implizite Hypothese dieses Schätzverfahrens ist, dass die ausstehende Bestellmenge über die Zeit hinweg bis auf zufällige Abweichungen konstant bleibt und entsprechend für die Prognose eingesetzt werden kann.

Analog zum Vorgehen von Bodily und Freeland (1988) bei der multiplikativen Methode glätten auch Guerrero und Elizondo (1997) die Prognose selbst exponentiell. Dabei wird die Vorhersage aus dem vorherigen Zeitraum $DF_{\text{Ae}(t_n+e-1)}$ wieder mit $1-\alpha$ gewichtet. Als neue Beobachtung wird $d_{\text{Aet}_n} + \hat{E}(U_{\text{Aet}_n}^*)$ mit dem Faktor α multipliziert. Entsprechend gilt dann:

$$DF_{\text{Ae}(t_n+e)} = \alpha \cdot (d_{\text{Aet}_n} + \hat{E}(U_{\text{Aet}_n}^*)) + (1 - \alpha) \cdot DF_{\text{Ae}(t_n+e-1)} \quad (7.2.11)$$

Zu beachten ist, dass sich die Variable $U_{\text{Aet}_n}^*$ von U_{Aet_n} unterscheidet. Es gilt $U_{\text{Aet}_n}^* = U_{\text{Aet}_n} + D_{\text{A}(e+1)t_n} \cdot U_{\text{Aet}_n}^*$ umfasst also die gesamte tatsächliche Nachfrage bis auf d_{Aet_n} . Ent-

⁷Die gleiche Annahme wird auch bei der Verwendung exponentieller Glättung getroffen.

sprechend ist $D_{A0t_n} = U_{Aet_n}^* + d_{Aet_n}$. Den dazugehörigen durchschnittlichen Wert $\hat{E}(U_{Aet_n}^*)$ ermitteln Guerrero und Elizondo (1997) sowohl als arithmetisches Mittel $\mu(t_1, t_n, U_{Aes}^*)$ als auch per exponentieller Glättung.

Auch der Einsatz verschiedener Varianten der additiven Prognosemethode wird im Anhang in Abschnitt A.2 exemplarisch vorgeführt.

7.2.2.3. Hybride Prognosemethode

Die Idee der hybriden Methoden wurde als erstes von Kekre u.a. (1990) formuliert, allerdings nicht weiter ausgearbeitet. Guerrero und Elizondo (1997) stellen die hybride Prognosemethode detailliert vor. Zusätzlich führen sie noch zwei Varianten der hybriden Prognosemethode ein. Alle drei Varianten werden hier kurz erläutert.

Die erste Variante entspricht der in Abschnitt 7.2.2 in Formel 7.2.5 vorgestellten hybriden Methode, wobei als Schätzverfahren das in Kapitel 4 erläuterte Vorgehen zur Minimierung des MSE benutzt wird. Es gilt also:⁸

$$\hat{\beta}_0(D_{Aet_n}, D_{A0t_n}) = \mu(t_1, t_n, D_{A0s}) - \hat{\beta}_1(D_{Aet_n}, D_{A0t_n}) \cdot \mu(t_1, t_n, D_{Aes}) \quad (7.2.12)$$

und

$$\hat{\beta}_1(D_{Aet_n}, D_{A0t_n}) = \frac{CoV(t_1, t_n, D_{Aes}, D_{A0s})}{\sigma(t_1, t_n, D_{Aes})^2} \quad (7.2.13)$$

In der in Gleichung 7.2.5 vorgestellten Prognosefunktion ist $\hat{\beta}_0(D_{Aet_n}, D_{A0t_n})$ der Schätzwert für den y-Achsenabschnitt und $\hat{\beta}_1(D_{Aet_n}, D_{A0t_n})$ für die Steigung der linearen Regressionsgleichung. Der Wert $\hat{\beta}_0(D_{Aet_n}, D_{A0t_n})$ entspricht dem aus Gleichung 7.2.5 resultierenden Prognosewert, wenn mit einer Vorlaufzeit von e noch keine Bestellungen für den Wunschliefzeitpunkt $t_n + e$ vorliegen. Durch die Multiplikation von $\hat{\beta}_1(D_{Aet_n}, D_{A0t_n})$ mit der zu einer Vorlaufzeit von e vorliegenden Bestellmenge $D_{Ae(t_n+e)}$ kann die Steigerung des Prognosewerts gegenüber dem y-Achsenabschnitt $\hat{\beta}_0(D_{Aet_n}, D_{A0t_n})$ berechnet werden, wie ebenfalls in Gleichung 7.2.5 ersichtlich ist.

Die zweite Variante von Guerrero und Elizondo (1997) weicht etwas von dem in Formel 7.2.5 vorgestellten Vorgehen ab. Sie sucht eine Korrelation in der Veränderung der Nachfrage. Wenn eine Prognose mit der Vorlaufzeit e erstellt werden soll, wird die Veränderung der kumuliert vorliegenden Bestellmenge zur Vorlaufzeit e für aufeinanderfolgende Wunschliefzeiten betrachtet. Für die vergangenen Wunschlieferttermine t_k und t_{k-1} ist dies beispielsweise die Differenz $DD_{Aet_k} = D_{Aet_k} - D_{Aet_{k-1}}$. Es wird nun die Korrelation zwischen dieser Veränderung und der dazugehörigen Differenz der späteren tatsächlichen Nachfrage $DD_{A0t_k} = D_{A0t_k} - D_{A0t_{k-1}}$ analysiert. Formel 7.2.14 beschreibt die entsprechende Prognosemethode.

⁸Zur Definition der Kovarianz in Formel 7.2.13 vgl. Formel 5.1.7 in Kapitel 5.

$$DF_{Ae(t_n+e)} - D_{A0t_n} = \hat{\beta}_0(DD_{Aet_n}, DD_{A0t_n}) + \hat{\beta}_1(DD_{Aet_n}, DD_{A0t_n}) \cdot (D_{Ae(t_n+e)} - D_{Aet_n}) \quad (7.2.14)$$

Das Schätzverfahren zur Berechnung von $\hat{\beta}_0(DD_{Aet_n}, DD_{A0t_n})$ und $\hat{\beta}_1(DD_{Aet_n}, DD_{A0t_n})$ entspricht dem aus Formel 7.2.12 bzw. 7.2.13, wobei D_{Aet_n} durch DD_{Aet_n} und D_{A0t_n} durch DD_{A0t_n} zu ersetzen ist. t_n ist der aktuelle Zeitpunkt und damit auch der letzte Zeitpunkt, für den die tatsächliche Nachfrage D_{A0t_n} bekannt ist. In die Regressionsgleichung 7.2.14 wird die Differenz $D_{Ae(t_n+e)} - D_{Aet_n}$ eingesetzt. $D_{Ae(t_n+e)}$ entspricht der aktuell kumuliert vorliegenden Bestellmenge für den zu prognostizierenden Wunschlieferzeitpunkt $t_n + e$. D_{Aet_n} ist die Bestellmenge, die für die tatsächliche Nachfrage des aktuellen Zeitpunkts mit einer Vorlaufzeit von e kumuliert vorlag. Die Regressionsgleichung gibt nun mit $DF_{Ae(t_n+e)} - D_{A0t_n}$ die Differenz zwischen der erwarteten Nachfrage für den Wunschlieferzeitpunkt $t_n + e$ und der tatsächlichen Nachfrage zum aktuellen Zeitpunkt wieder. Wird der bekannte Wert D_{A0t_n} hinzuaddiert, verbleibt nur der zu bestimmende Prognosewert $DF_{Ae(t_n+e)}$. Diese Form der hybriden Methode ist also zunächst auf die Vorhersage der absoluten Nachfrageveränderung fokussiert, um daraus dann die Prognose der tatsächlichen Nachfrage abzuleiten.

Eine dritte Version der hybriden Methode ergänzt die in Formel 7.2.5 vorgestellte Variante um eine Trendkomponente. Sie ist in Formel 7.2.15 dargestellt.

$$DF_{Ae(t_n+e)} = \hat{\beta}_0(D_{Aet_n}, D_{A0t_n}) + \hat{\beta}_1(D_{Aet_n}, D_{A0t_n}) D_{Ae(t_n+e)} + \hat{\beta}_2(D_{Aet_n}, D_{A0t_n}) (t_n + e) \quad (7.2.15)$$

Durch $\hat{\beta}_2(D_{Aet_n}, D_{A0t_n}) \cdot (t_n + e)$ wird ein zeitlicher Trend in der Prognosemethode berücksichtigt. Da Gleichung 7.2.15 mit $D_{Ae(t_n+e)}$ und $(t_n + e)$ zwei unabhängige Variablen enthält, sind die in Kapitel 4 vorgestellten Verfahren für eine einfache lineare Regression nicht mehr anwendbar. Die Verfahren zur Bestimmung der Schätzer $\hat{\beta}_0(D_{Aet_n}, D_{A0t_n})$, $\hat{\beta}_1(D_{Aet_n}, D_{A0t_n})$ und $\hat{\beta}_2(D_{Aet_n}, D_{A0t_n})$ werden hier nicht detailliert erläutert. Sie sind in der verbreiteten Statistikkliteratur zu finden.⁹

Utley und May (2010) stellen eine weitere hybride Methode vor. Im Gegensatz zu der Variante aus Formel 7.2.14 basiert sie auf der relativen statt der absoluten Veränderung des Bestellverhaltens. Für die vergangenen Wunschliefertermine t_k und t_{k-1} ist die relative Veränderung der zur Vorlaufzeit e kumuliert vorliegende Bestellmenge als $DR_{Aet_k} = D_{Aet_k} / D_{Aet_{k-1}}$ definiert. Die entsprechende Veränderung der späteren tatsächlichen Nachfrage ist $DR_{A0t_k} = D_{A0t_k} / D_{A0t_{k-1}}$. Sei zusätzlich $DRF_{Ae(t_n+e)}$ die Vorhersage der relativen Veränderung der tatsächlichen Nachfrage von $t_n + e - 1$ auf $t_n + e$. Es gilt:

$$DRF_{Ae(t_n+e)} = \hat{\beta}_0(DR_{Aet_n}, DR_{A0t_n}) + \hat{\beta}_1(DR_{Aet_n}, DR_{A0t_n}) \cdot DR_{Ae(t_n+e)} \quad (7.2.16)$$

⁹Guerrero und Elizondo (1997) führen diese Formeln nicht explizit auf, aber sie sind beispielsweise bei Makridakis und Wheelwright (1989, S. 183–209), Makridakis u.a. (1998, S. 240–310), Hartung u.a. (1998, S. 595–600) sowie Ramanathan (2002, S. 144–209) enthalten.

Zu Bestimmung von $\hat{\beta}_0(DR_{Aet_n}, DR_{A0t_n})$ und $\hat{\beta}_1(DR_{Aet_n}, DR_{A0t_n})$ können wieder analog die Formeln 7.2.12 und 7.2.13 verwendet werden, wobei diesmal D_{Aet_n} und D_{A0t_n} durch DR_{Aet_n} bzw. DR_{A0t_n} zu substituieren sind. Mit $DR_{Ae(t_n+e)} = D_{Ae(t_n+e)} / D_{Ae(t_n+e-1)}$ wird in die Gleichung die relative Veränderung der zur Vorlaufzeit e kumuliert vorliegenden Bestellmenge zwischen den Wunschliefzeitpunkten $t_n + e - 1$ und $t_n + e$ eingesetzt. Falls $e = 1$ gilt, so ist $t_n + e - 1 = t_n$ und somit ist die tatsächliche Nachfrage $D_{A0(t_n+e-1)} = D_{A0t_n}$ bekannt. Für die Prognose der zukünftigen Nachfrage gilt dann:

$$DF_{A1(t_n+1)} = DRF_{A1(t_n+1)} \cdot D_{A0t_n} \quad (7.2.17)$$

Wenn andernfalls $e > 1$, dann wird die tatsächliche Nachfrage D_{A0t_n} durch die aktuelle Prognose $DF_{A(e-1)(t_n+e-1)}$ für den vorherigen Zeitpunkt $t_n + e - 1$ substituiert, die mit einer Vorlaufzeit $e-1$ getätigt wurde. Es gilt also:

$$DF_{Ae(t_n+e)} = DRF_{Ae(t_n+e)} \cdot DF_{A(e-1)(t_n+e-1)} \quad (7.2.18)$$

Die Methode von Utley und May (2010) prognostiziert also zunächst die relative Veränderung der tatsächlichen Nachfrage gegenüber dem vorherigen Zeitpunkt. Aus dieser vorhergesagten Veränderung wird durch Multiplikation mit der tatsächlichen oder ebenfalls prognostizierten Nachfrage des vorherigen Zeitpunkts die Nachfrageprognose abgeleitet. Der Einsatz von drei Varianten der hybriden Prognosemethode wird exemplarisch im Anhang in Abschnitt A.3 dargestellt. Es werden zwei Versionen von Guerrero und Elizondo (1997) benutzt. Dies ist zunächst die in Gleichung 7.2.5 beschriebene Variante mit den Schätzverfahren aus den Gleichungen 7.2.12 und 7.2.13. Außerdem wird der Einsatz der in Formel 7.2.14 gezeigten Version vorgeführt. Zusätzlich wird die Version von Utley und May (2010) aus den Gleichungen 7.2.16 bis 7.2.18 verwendet.

7.2.2.4. Übersicht weiterer Veröffentlichungen

Neben den beschriebenen Veröffentlichungen gibt es Arbeiten, die die praktischen Erfahrungen mit den Methoden dokumentieren. Haberleitner u.a. (2010) setzen die additive Methode in einer Supply Chain aus der Industrie für feuerfeste Materialien ein. Dabei wurde unter anderem auch die kommerzielle Prognosesoftware SAS Analytics eingesetzt. Basierend auf der Zeitreihe vergangener Werte wählt diese Software ein Modell von Winters (1960) als am besten geeignetes Schätzverfahren für $\hat{E}(U_{Aet_n})$ aus. Im Beispiel von Haberleitner u.a. (2010) liefert die additive Methode vor allem bei kurzfristigen Vorhersagen bessere Resultate als die konventionellen Prognosemethoden. Darüber hinaus erkennt die additive Methode im betrachteten Fall bei Haberleitner u.a. (2010) einen Umsatzeinbruch eher als konventionelle Methoden, da sie den Bestellungsrückgang berücksichtigt, der den Einbruch frühzeitig ankündigt.

Lee und Connors (2006) testen den Einsatz der multiplikativen, additiven und hybriden Methode zur Vorhersage des Personalbedarfs in IBM's IT Services Business in Indien. Sie verwenden exponentielle Glättung zur Bestimmung der Schätzwerte bei der multiplikativen und additiven Methode. Bei der hybriden Methode verwenden sie die Formeln 7.2.12

und 7.2.13, um $\hat{\beta}_0(D_{\text{Act}_n}, D_{\text{A0t}_n})$ bzw. $\hat{\beta}_1(D_{\text{Act}_n}, D_{\text{A0t}_n})$ abzuschätzen. Sie vergleichen die Methoden mit einem einfachen Modell, das den vergangenen Personalbedarf zur Vorhersage des künftigen exponentiell glättet. Von den vier untersuchten Methoden liefert die hybride Prognosemethode die besten Ergebnisse.

Weitere Ansätze für ADI-basierte Methoden werden von Habla u.a. (2007) vorgestellt. Die Methoden entsprechen weder der multiplikativen, additiven noch der hybriden Methode und sind teilweise deutlich komplexer. Sie werden hier nicht detailliert vorgestellt, da sie in dieser Arbeit nicht wieder aufgegriffen werden.

7.3. Analyse verschiedener Prognosemethoden

In diesem Abschnitt wird nun der Einfluss des Bestellverhaltens auf die in Abschnitt 7.2.2 vorgestellten ADI-basierten Prognosemethoden analytisch untersucht. Wie zu Beginn dieses Kapitels kurz beschrieben, variiert die Prognosegenauigkeit bei den ADI-basierten Methoden stark. Die Möglichkeit, diese Genauigkeit vor einer aufwendigen Implementierung abschätzen zu können, ist der wesentliche motivierende Faktor für die nun folgende Analyse. Entsprechend werden in Abschnitt 7.3.1 zunächst die Motivation und einige Annahmen für diese Analyse dargestellt. Es folgt in Abschnitt 7.3.2 die eigentliche Analyse der Methoden und die Ableitung einiger für die Prognosegenauigkeit relevanter Kennzahlen.

7.3.1. Annahmen und Motivation der Analyse

ADI-basierte Prognosemethoden können hervorragende Prognosen der zukünftigen Nachfrage liefern. So erkennen sie durch die Berücksichtigung der ADI plötzliche starke Veränderungen in der Nachfrage teilweise eher als konventionelle Methoden, da sich dieser Wandel der Nachfrage häufig frühzeitig durch veränderte Bestellmengen ankündigt. Allerdings sind die ADI-basierten nicht immer den konventionellen Prognosemethoden überlegen. In einigen Situationen sind die durch konventionelle Methoden erstellten Prognosen genauer, wie bereits Haberleitner u.a. (2010) bei der Anwendung der ADI-basierten Methoden in einer Supply Chain zur Produktion feuerfester Materialien festgestellt haben.

Wie Haberleitner u.a. (2010) ebenfalls ausführen, existieren aktuell keine standardisierten Softwaremodule, die eine Implementierung der ADI-Methoden enthalten. Supply Chains, die die ADI-basierten Prognosemethoden nutzen möchten, müssen die notwendige Implementierung in einem APS entsprechend eigenständig planen und durchführen. Der Einsatz dieser Methoden ist entsprechend aufwendig und impliziert ein signifikantes Investment von häufig knappen IT-Ressourcen. Den mit der Implementierung verbundenen Kosten steht nun das Risiko gegenüber, dass die ADI-basierten Methoden ungenauere Prognosen als die konventionellen Verfahren erstellen. Es ist für eine Supply Chain deshalb von großem Nutzen, wenn sie vorab die Prognosegenauigkeit der ADI-basierten Methoden ermitteln und vergleichen sowie die Erfolgsaussichten einer Implementierung realistisch bewerten kann.

Ziel dieses Abschnitts ist es deshalb, Kennzahlen abzuleiten, die es erlauben, die zu erwartende Genauigkeit der verschiedenen Prognosemethoden ohne den Aufwand einer

Implementierung abzuschätzen. Die Kennzahlen sollen dabei einzig auf Grundlage der ex-post vorliegenden verallgemeinerten Auftragsprofile berechnet werden. Sie ermöglichen so den einfachen Vergleich der unterschiedlichen Prognosemethoden und erlauben es einer Supply Chain, den Mehrwert der Prognosemethoden vor einer Implementierung in einem APS abzuschätzen. Die Berechnung der Kennzahlen ist darüber hinaus einfacher als die Simulation der ADI-basierten Prognosemethoden mit ex-post Daten in einem Tabellenkalkulationsprogramm, um deren Genauigkeit zu beurteilen. Voraussetzung für die Simulation ist ein genaues Verständnis der ADI-basierten Prognosemethoden, um diese zu implementieren, welches in vielen Supply Chains nicht vorhanden ist und zunächst erarbeitet werden muss. Außerdem müssen für die Simulation einiger Prognosemethoden zusätzliche Parameter ermittelt werden. So gibt es beispielsweise Prognosemethoden, für die der Parameter α zur Durchführung einer exponentiellen Glättung im Rahmen der Simulation bestimmt werden muss. Die Ermittlung dieser Parameter ist bei Verwendung der Kennzahlen ebenfalls nicht notwendig. Die Nutzung der Kennzahlen ermöglicht im Vergleich eine einfache und schnelle Einschätzung der zu erwartenden Prognosegenauigkeit.

Es gibt verschiedene Vorgehensweisen, die Genauigkeit einer Prognosemethode ex-post zu analysieren. Neben der bereits erwähnten Simulation der Prognosemethode mit ex-post Daten beschreibt Küsters (2005) weitere Herangehensweisen. Wie die Simulation implizieren leider viele dieser Verfahren die Implementierung der Prognosemethode. In Anlehnung an eine von Küsters (2005) beschriebene Vorgehensweise besteht allerdings die Möglichkeit, ohne eine Programmierung der Prognosemethoden die zu erwartende Genauigkeit der Vorhersagen abzuschätzen.

Wie im letzten Abschnitt beschrieben, sind für die verschiedenen ADI-basierten Prognosemethoden unterschiedliche Schätzer zu berechnen. Für die multiplikative Methode ist beispielsweise ein Schätzer für den Erwartungswert der anteilig vorliegenden Bestellmenge $E(X_{Aet_n})$ zu bestimmen. Zur Berechnung dieser Schätzer können unterschiedliche Verfahren eingesetzt werden, wie ebenfalls im letzten Abschnitt umfassend dargestellt. Im Fall der multiplikativen Methode kann zum Beispiel das arithmetische Mittel $\mu(t_1, t_n, X_{Aes})$ als Schätzer für $E(X_{Aet_n})$ verwendet werden. Die prognostizierte und tatsächliche Nachfrage werden dabei nur übereinstimmen, wenn der ermittelte Schätzwert dem tatsächlichen Wert entspricht. Im Fall der multiplikativen Methode gilt dies, wenn der Schätzer für $E(X_{Aet_n})$ und der tatsächliche Wert $X_{Ae(t_n+e)}$ identisch sind. Wie bereits in Abschnitt 7.1 erläutert, können sowohl eine systematische Fehleinschätzung von $E(X_{Aet_n})$ als auch die zufällige Streuung der tatsächlichen Werte dazu führen, dass die beiden Werte nicht gleich sind. Der Einfluss der systematischen Fehleinschätzung wird als Niveau und der zufälligen Abweichungen als Streuung des Prognosefehlers bezeichnet. Ein systematischer Fehler liegt bei der multiplikativen Methode mit dem beschriebenen arithmetischen Mittel als Schätzer vor, wenn die Zeitreihe der anteilig vorliegenden Bestellmenge für eine Vorlaufzeit von e bis auf zufällige Abweichungen nicht konstant ist.

Die Analyse in diesem Abschnitt soll den Einfluss, den eine Abweichung von Schätzwert und tatsächlichem Wert auf den resultierenden Prognosefehler hat, bestimmen. Die folgende Analyse ist auf die Streuung des Prognosefehlers konzentriert. Es wird davon ausgegangen, dass das von Tempelmeier (2008, S. 33–36) beschriebene Niveau des Pro-

gnosefehlers null ist.¹⁰ Wie in Abschnitt 7.1 beschrieben, ist ein positives oder negatives Niveau des Prognosefehlers durch systematische Fehleinschätzung des Anwenders bedingt, während die Streuung des Prognosefehlers nicht durch den Nutzer zu beeinflussen ist. Es wird an dieser Stelle davon ausgegangen, dass der Anwender die geeigneten Schätzverfahren auswählt. Der Fokus der Analyse liegt auf der verbleibenden zufälligen Streuung des Prognosefehlers. Die entsprechenden Kennzahlen zur Bewertung dieser Streuung werden in der Analyse in Abschnitt 7.3.2 detailliert abgeleitet und beschrieben. Dieser Analyseschwerpunkt impliziert nun die folgenden zwei Annahmen:

1. Die ex-post vorliegende Zeitreihe wird durch die Prognosemethode nicht systematisch falsch eingeschätzt.
2. Die Zeitreihe verändert sich zukünftig nicht systematisch.

In Abbildung 7.4 sind exemplarisch Situationen illustriert, in denen eine solche systematische Fehleinschätzung bzw. Veränderung der Zeitreihe vorliegen.¹¹ In beiden Situationen tritt eine systematische Fehleinschätzung der zukünftigen Werte auf und das Niveau des Prognosefehlers ist nicht null. Mit den beiden Annahmen als Grundlage für die weitere Analyse kann davon ausgegangen werden, dass die ex-post ermittelten Abweichungen als auch die zukünftigen Prognosefehler zufällig und identisch unabhängig verteilt sind und somit kein systematischer Fehler auftreten wird.

Um die zu erwartende Prognosegenauigkeit zu bestimmen, wird nun die Streuung der ex-post vorliegenden Zeitreihenwerte um das für die jeweilige ADI-basierte Methode verwendete statistische Modell analysiert. Wenn das Modell einer konstanten Zeitreihe eingesetzt wird, wird beispielsweise bei der additiven Methode die Streuung der Zeitreihe der ausstehenden Bestellmengen um das arithmetische Mittel $\mu(t_1, t_n, U_{Aes})$ untersucht. Die im folgenden Abschnitt erarbeiteten Kennzahlen zeigen den Zusammenhang zwischen dieser Streuung und der zu erwartenden Prognosegenauigkeit erstmalig auf und erlauben auf diesem Weg die Bewertung der ADI-basierten Methoden.

Es ist hervorzuheben, dass sich die getroffenen Annahmen nicht auf die beschriebene Eigenschaft der ADI-basierten Methoden, Veränderungen in der tatsächlichen Nachfrage frühzeitig zu erkennen, beziehen bzw. solche Veränderungen ausschließen. Diese Eigenschaft der ADI-basierten Methoden beruht darauf, dass Veränderungen in der Nachfrage

¹⁰Ein entsprechendes Testverfahren, um zu überprüfen, ob das Niveau des Prognosefehlers null ist, wurde in Abschnitt 7.1 vorgestellt.

¹¹Im linken Graphen ist die Situation aus Abbildung 7.2 übernommen, die eine systematische Fehleinschätzung beschreibt. Es wurde das Zeitreihenmodell einer konstanten Nachfrage für eine Zeitreihe mit Trend verwendet. Die Abweichungen der Prognosen von den tatsächlichen Werten sind deutlich höher als die ex-post zu beobachtende Streuung der Zeitreihe um das durch eine durchgezogene Linie markierte Modell. Grund dafür ist die zukünftige systematische Unterschätzung der Nachfrage durch die Prognosemethode, die den Trend nicht berücksichtigt. Im rechten Graphen verändert sich die Zeitreihe systematisch. Die ex-post beobachteten Werte weisen einen klar positiven Trend auf. Die Zeitreihe verändert sich nun in der Zukunft. Sie hat dort einen negativen Trend. Die Prognose, die auf den Vergangenheitswerten beruht, sagt allerdings einen weiteren Anstieg voraus und führt so zu einer massiven Fehleinschätzung. Die Abweichungen der Prognosen von den tatsächlichen Werten sind auch hier deutlich höher als die ex-post vorliegende Streuung.




Abbildung 7.4.: Einfluss systematischer Fehleinschätzungen bzw. Veränderungen auf die Prognosegenauigkeit

frühzeitig in den Bestellmengen reflektiert werden. Bei diesen veränderten Bestellmengen handelt es sich um tatsächliche Werte, die der Supply Chain zum Zeitpunkt der Prognose vorliegen. Sie unterliegen keiner Schätzung. Die beiden Annahmen betreffen hingegen die Schätzverfahren, die den Prognosemethoden zugrunde liegen. Im Fall der multiplikativen Methode basiert dieses Schätzverfahren beispielsweise auf der Zeitreihe der anteilig vorliegenden Bestellmenge, wenn das arithmetische Mittel $\mu(t_1, t_n, X_{Aes})$ als Schätzer für $E(X_{Aet_n})$ verwendet wird. Dadurch wird implizit die Annahme getroffen, dass die Zeitreihe der anteilig vorliegenden Bestellmenge für eine Vorlaufzeit von e bis auf zufällige Abweichungen konstant ist. Ähnlich liegt der additiven Methode die Hypothese zugrunde, dass die Zeitreihe der ausstehenden Bestellmenge bis auf zufällige Abweichungen konstant ist, wenn $\mu(t_1, t_n, U_{Aes})$ als Schätzer für $E(U_{Aet_n})$ benutzt wird. Da diese Schätzverfahren der ADI-basierten Verfahren nicht die Konstanz der tatsächlichen Nachfrage voraussetzen, ist die beschriebene Eigenschaft der ADI-basierten Methoden hier nicht direkt betroffen. Einzig bei der Analyse des Modells einer konstanten Nachfrage wird hier auch eine Konstanz der tatsächlichen Nachfrage vorausgesetzt. Liegt keine Konstanz der tatsächlichen Nachfrage vor, ist dieses Modell für die Prognose der zukünftigen Nachfrage aufgrund der damit verbundenen systematischen Fehleinschätzung ohnehin ungeeignet.

Im folgenden Abschnitt werden nun die Kennzahlen abgeleitet, die es erlauben, die zukünftige Prognosegenauigkeit abzuschätzen. Wie gezeigt werden wird, sind diese Kennzahlen abhängig vom Bestellverhalten der Kunden. Der Zusammenhang zwischen den Prognosemethoden und den in Kapitel 5 vorgestellten Kennzahlen zur Charakterisierung des Bestellverhaltens wird anschließend in Abschnitt 7.4 dargestellt.

7.3.2. Abschätzung der Prognosegenauigkeit

In diesem Abschnitt werden die Kennzahlen zur erwarteten Genauigkeit der Prognosemethoden abgeleitet. Untersucht werden dabei die Prognosemethoden, die durch die Gleichungen 7.2.1 bis 7.2.5 beschrieben werden. Andere Varianten dieser Prognosemethoden, wie sie beispielsweise für die hybride Methode in den Formeln 7.2.14 und 7.2.15 dargestellt werden, werden nicht analysiert.

Für die folgende Analyse wird t_n als der die Gegenwart markierende Zeitpunkt betrachtet. Ex-post liegen verallgemeinerte Auftragsprofile seit dem Zeitpunkt t_1 bereit. Untersucht werden die Prognosen mit einer Vorlaufzeit von e für die zukünftigen Zeitpunkte $t_n + e$ bis $t_n + m + e$.

Im vorherigen Abschnitt wurde die Annahme getroffen, dass das verwendete Schätzverfahren die zugrunde liegende Zeitreihe in Vergangenheit und Zukunft nicht systematisch falsch einschätzt. Dies bedeutet gleichzeitig, dass das erwartete zukünftige Niveau des Prognosefehlers 0 ist. Unabhängig von der Vorlaufzeit e gilt für den durchschnittlichen Prognosefehler also:

$$\hat{\mu}(t_n + e, t_n + m + e, EA_{Aes}) = \hat{\mu}(t_n + e, t_n + m + e, ER_{Aes}) = 0$$

Um die Genauigkeit der Prognosemethoden zu bewerten, ist die Streuung des Prognosefehlers abzuschätzen. Gesucht sind also Schätzer der absoluten und relativen Streuungswerte $\hat{\sigma}(t_n + e, t_n + m + e, EA_{Aes})$ bzw. $\hat{\sigma}(t_n + e, t_n + m + e, ER_{Aes})$. Wie im letzten Abschnitt angenommen wurde, eignen sich die ex-post beobachteten Abweichungen der tatsächlichen Werte von der modellierten Prognosemethode als Schätzer dafür. Es gilt also:

$$\hat{\sigma}(t_n + e, t_n + m + e, EA_{Aes}) = \sigma(t_1, t_n, EA_{Aes}) \quad (7.3.1)$$

$$\hat{\sigma}(t_n + e, t_n + m + e, ER_{Aes}) = \sigma(t_1, t_n, ER_{Aes}) \quad (7.3.2)$$

Ziel der folgenden Untersuchung ist es nun, $\sigma(t_1, t_n, EA_{Aes})$ und $\sigma(t_1, t_n, ER_{Aes})$ zu bestimmen, ohne eine Prognosemethode zu implementieren. Der Streuungswert wird an dieser Stelle exemplarisch für die additive Prognosemethode hergeleitet.

Gemäß Gleichung 7.2.4 gilt $DF_{Aes} = D_{Aes} + \hat{E}(U_{Ae(s-e)})$ für die additive Prognosemethode. Ferner wurde der absolute Prognosefehler in Abschnitt 7.1 folgendermaßen definiert: $EA_{Aes} = D_{A0s} - DF_{Aes}$. Entsprechend gilt nun:

$$\begin{aligned} EA_{Aes} &= D_{A0s} - DF_{Aes} \\ \Leftrightarrow EA_{Aes} &= D_{A0s} - (D_{Aes} + \hat{E}(U_{Ae(s-e)})) \\ \Leftrightarrow EA_{Aes} &= (D_{A0s} - D_{Aes}) - \hat{E}(U_{Ae(s-e)}) \end{aligned}$$

$$\Leftrightarrow EA_{Aes} = U_{Aes} - \hat{E}(U_{Ae(s-e)})$$

Der Prognosefehler entspricht also der Differenz zwischen der Schätzung $\hat{E}(U_{Ae(s-e)})$ und der tatsächlich zur Vorlaufzeit e noch ausstehenden Bestellmenge U_{Aes} . Je besser $\hat{E}(U_{Ae(s-e)})$ die noch ausstehende Bestellmenge U_{Aes} abschätzt, desto kleiner ist also der resultierende Prognosefehler EA_{Aes} . Die Streuung dieser Prognosefehler kann nun wie folgt abgeleitet werden. Analog zu Formel 3.2.2 aus Kapitel 3 gilt für den absoluten Streuungswert

$$\sigma(t_1, t_n, EA_{Aes}) = \sqrt{\sum_{m=t_1}^{t_n} (EA_{Aem} - \mu(t_1, t_n, EA_{Aes}))^2 / (n-1)}$$

Da eine systematische Fehleinschätzung ausgeschlossen wurde, ist $\mu(t_1, t_n, EA_{Aes}) = 0$ und somit gilt

$$\sigma(t_1, t_n, EA_{Aes}) = \sqrt{\sum_{m=t_1}^{t_n} (EA_{Aem})^2 / (n-1)}$$

Es kann nun abgeleitet werden:

$$\begin{aligned} \sigma(t_1, t_n, EA_{Aes}) &= \sqrt{\sum_{m=t_1}^{t_n} (EA_{Aem})^2 / (n-1)} \\ \Leftrightarrow \sigma(t_1, t_n, EA_{Aes}) &= \sqrt{\sum_{m=t_1}^{t_n} (U_{Aem} - \hat{E}(U_{Ae(m-e)}))^2 / (n-1)} \\ \Leftrightarrow \sigma(t_1, t_n, EA_{Aes}) &= \hat{\sigma}(t_1, t_n, U_{Aes}) \end{aligned}$$

Dabei entspricht $\hat{\sigma}(t_1, t_n, U_{Aes})$ der Streuung der ausstehenden Bestellmenge um den jeweiligen Schätzwert $\hat{E}(U_{Ae(s-e)})$. Entscheidend ist, welches Schätzverfahren im Rahmen der additiven Methode für $\hat{E}(U_{Ae(s-e)})$ eingesetzt wird. Aus der Abweichung der tatsächlich noch ausstehenden Bestellmengen U_{Aes} von diesen Schätzwerten resultiert direkt die Streuung der Prognosefehler. In Abschnitt 7.2.2.2 wurden die unterschiedlichen Schätzverfahren vorgestellt, die von verschiedenen Autoren in ihren Arbeiten hierfür verwendet wurden. Haberleitner u.a. (2010) setzen die kommerzielle Prognosesoftware SAS Analytics ein, um ein geeignetes Schätzverfahren für $\hat{E}(U_{Ae(s-e)})$ zu bestimmen. Die Software wählt in diesem Fall ein Modell von Winters (1960) dafür aus.

Hier wird die Annahme getroffen, dass die ausstehende Bestellmenge für ein festes e bis auf zufällige Abweichungen konstant ist.¹² Das arithmetische Mittel kann also als Schätzwert für alle $\hat{E}(U_{Ae(s-e)})$ benutzt werden. Es gilt dann $\hat{E}(U_{Ae(s-e)}) = \mu(t_1, t_n, U_{Aes})$, woraus gleichzeitig abgeleitet werden kann, dass $\hat{\sigma}(t_1, t_n, U_{Aes}) = \sigma(t_1, t_n, U_{Aes})$. Ist die

¹²Trifft diese Annahme nicht zu, sind entsprechend andere Schätzverfahren für die Analyse zu verwenden, die dann allerdings deutlich aufwendiger wird.

ausstehende Bestellmenge also bis auf zufällige Abweichungen konstant, entspricht deren Streuung gleichzeitig der Streuung des absoluten Prognosefehlers bei Verwendung der additiven Methode.

Eine analoge Bestimmung der relativen Streuung des Prognosefehlers $\sigma(t_1, t_n, ER_{Aes})$ ist für die additive Methode nicht möglich, wie die folgenden Ausführungen zeigen. Nach der Definition des relativen Fehlers gilt nämlich $\sigma(t_1, t_n, ER_{Aes}) = \sigma(t_1, t_n, EA_{Aes}/D_{A0s})$. Es ist also die Standardabweichung des Quotienten EA_{Aes}/D_{A0s} zu ermitteln. Die entsprechende Formel zur Varianzbestimmung eines Quotienten zweier Zufallsvariablen ist unter anderem in Mood u.a. (1974, S. 180–181) sowie James (2007, S. 33) enthalten. Für zwei Zufallsvariablen V und W mit Erwartungswerten $E(V)$ und $E(W)$ ist die Varianz des Quotienten demnach folgendermaßen abzuschätzen:

$$Var\left(\frac{V}{W}\right) \approx \left(\frac{E(V)}{E(W)}\right)^2 \cdot \left(\frac{Var(V)}{E(V)^2} + \frac{Var(W)}{E(W)^2} - \frac{2CoV(V, W)}{E(V) \cdot E(W)}\right) \quad (7.3.3)$$

Dabei liefert die Abschätzung nur gute Resultate, wenn sowohl $|E(V)| \gg Var(V)$ als auch $|E(W)| \gg Var(W)$ ist. Da allerdings angenommen wurde, dass $\mu(t_1, t_n, EA_{Aes}) = 0$ gilt, ist diese Voraussetzung für EA_{Aes} nicht erfüllt. Die Ableitung einer guten Abschätzung für $\sigma(t_1, t_n, ER_{Aes})$ ist deshalb nicht einfach möglich.

Schätzer für die absolute Streuung des Prognosefehlers können analog für die hybride Methode sowie die beiden Modelle aus der klassischen Zeitreihenanalyse, die in Abschnitt 7.2.1 vorgestellt wurden, abgeleitet werden. Wie in Abschnitt 7.3.1 beschrieben, basieren die Kennzahlen auf der Annahme, dass die Modelle nur für Zeitreihen eingesetzt werden, die sie nicht systematisch falsch einschätzen würden. Die Kennzahl zum Modell konstanter Nachfrage ist also nur gültig, wenn das Modell für Prognosen eingesetzt wird, die auf einer konstanten Zeitreihe fundieren. Weist die Zeitreihe beispielsweise einen Trend auf, dann ist das entsprechende den Trend berücksichtigende Modell hier zu benutzen. Die Kennzahl zur hybriden Methode fundiert auf der Annahme, dass die Gleichungen 7.2.12 und 7.2.13 zur Berechnung der beiden Schätzwerte für die hybride Methode geeignet sind. Das Vorliegen der in Kapitel 4 erläuterten Autokorrelation oder Heteroskedastizität würden dieser Eignung beispielsweise entgegenstehen. Die Schätzverfahren und Kennzahlen sind in einem solchen Fall anzupassen. Entsprechend den Ableitungen in Anhang B ergeben sich nun folgende Schätzer für die unterschiedlichen Prognosemethoden bei einer Vorlaufzeit von e :

- Modell konstanter Nachfrage: $\sigma(t_1, t_n, D_{A0s})$
- Modell einer Zeitreihe mit Trend:¹³ $\sigma(t_1, t_n, D_{A0s}) \cdot \sqrt{1 - R(t_1, t_n, D_{A0s})^2}$
- Additive Methode: $\sigma(t_1, t_n, U_{Aes})$
- Hybride Methode: $\sigma(t_1, t_n, D_{A0s}) \cdot \sqrt{1 - R(t_1, t_n, D_{Aes}, D_{A0s})^2}$

¹³ $R(t_1, t_n, D_{A0s})$ ist der Korrelationskoeffizient zwischen den Zeitpunkten t_1 bis t_n und der entsprechenden tatsächlichen Nachfrage.

Einfache Schätzer für die relative Streuung können für diese Prognosemethoden aus demselben Grund wie bei der additiven Methode nicht ermittelt werden.

Wie in Anhang B.4 ausgeführt wird, wird auf die Ableitung einer Kennzahl zum absoluten Streuungswert bei der multiplikativen Methode verzichtet, da sie äußerst komplex ist. Die relative Streuung kann dafür hier einfach mit dem Variationskoeffizienten der anteilig vorliegenden Bestellmenge $VK(t_1, t_n, X_{Aes})$ abgeschätzt werden. Diese Kennzahl für die multiplikative Methode beruht auf der Annahme, dass die Zeitreihe der anteilig vorliegenden Bestellmengen bei einer Vorlaufzeit von e bis auf identisch unabhängig verteilte Abweichungen konstant ist und entsprechend ohne systematische Fehleinschätzungen durch das arithmetische Mittel $\mu(t_1, t_n, X_{Aes})$ abgeschätzt werden kann.

Wie in Abschnitt 7.1 beschrieben, sind MSE, MAD und MAPE Standardmaße zur Bewertung der Prognosequalität. Es besteht die Möglichkeit, die abgeleiteten Kennzahlen zu diesen Standardmaßen in Bezug zu setzen. Wenn $\hat{\sigma}_{EA}$ die geschätzte Standardabweichung des absoluten Prognosefehlers ist, eignet sich diese unter anderem nach Silver u.a. (1998, S. 111–112) als Schätzer der Quadratwurzel des zu erwartenden MSE: $\hat{\sigma}_{EA} = \sqrt{MSE}$. Bereits Brown (1959, S. 89 ff.) hat für die MAD gezeigt, dass $\hat{\sigma}_{EA} = \sqrt{\pi/2} \cdot MAD$ gilt, wenn der absolute Prognosefehler normalverteilt ist. Analog zu Brown (1959, S. 89 ff.) gilt für den relativen Prognosefehler dann $\hat{\sigma}_{ER} = \sqrt{\pi/2} \cdot MAPE$, wenn dieser normalverteilt ist.¹⁴

Für die Kennzahlen zu den verschiedenen Prognosemethoden, die ebenfalls auf eine Aggregationsebene A und Vorlaufzeit e bezogen sind, bestehen dann die in Tabelle 7.3 aufgeführten Zusammenhänge. Sie sind dabei an die beschriebenen Annahmen gebunden. Die Kennzahlen ermöglichen eine Abschätzung der zu erwartenden Prognosegenauigkeit und damit auch einen Vergleich der Methoden.

	MSE_{Ae}
Additive Methode	$\sigma(t_1, t_n, U_{Aes})^2$
Hybride Methode	$\sigma(t_1, t_n, D_{A0s})^2 \cdot (1 - R(t_1, t_n, D_{Aes}, D_{A0s}))^2$
Modell konstanter Nachfrage	$\sigma(t_1, t_n, D_{A0s})^2$
Modell einer Zeitreihe mit Trend	$\sigma(t_1, t_n, D_{A0s})^2 \cdot (1 - R(t_1, t_n, D_{A0s}))^2$
	MAD_{Ae}
Additive Methode	$\sqrt{2/\pi} \cdot \sigma(t_1, t_n, U_{Aes})$
Hybride Methode	$\sqrt{2/\pi} \cdot \sigma(t_1, t_n, D_{A0s}) \cdot \sqrt{1 - R(t_1, t_n, D_{Aes}, D_{A0s})^2}$
Modell konstanter Nachfrage	$\sqrt{2/\pi} \cdot \sigma(t_1, t_n, D_{A0s})$
Modell einer Zeitreihe mit Trend	$\sqrt{2/\pi} \cdot \sigma(t_1, t_n, D_{A0s}) \cdot \sqrt{1 - R(t_1, t_n, D_{A0s})^2}$
	$MAPE_{Ae}$
Multiplikative Methode	$\sqrt{2/\pi} \cdot VK(t_1, t_n, X_{Aes})$

Tabelle 7.3.: Zusammenhang MSE, MAD und MAPE und Kennzahlen

¹⁴ $\hat{\sigma}_{ER}$ ist die geschätzte Standardabweichung des relativen Prognosefehlers.

7.4. Einfluss des Bestellverhaltens auf die Prognosegenauigkeit

Die ADI-basierten Prognosemethoden basieren die Vorhersage zukünftiger Nachfrage auf Bestellinformationen. Im vergangenen Abschnitt wurden einige Kennzahlen zur Abschätzung der zu erwartenden Prognosegenauigkeit analytisch hergeleitet. Diese Werte werden nun mit den Kennzahlen aus Kapitel 5 abgeglichen, um die Eignung ADI-basierter Methoden für ein gewisses charakteristisches Bestellverhalten zu bestimmen. Untersucht wird dabei der Einfluss der Kennzahlen zur Spannweite (Abschnitt 7.4.1), zu Durchschnitt und Form der Streuung (Abschnitt 7.4.2), zur Korrelation (Abschnitt 7.4.3) und zur Konstanz der Bestellmengen (Abschnitt 7.4.4). Mit den Kennzahlen kann unter anderem der Vorlaufzeitrahmen bestimmt werden, in dem sich der Einsatz ADI-basierter Prognosemethoden eignet. Des Weiteren werden unterschiedliche Aspekte beleuchtet, die Einfluss auf das zu erwartende Niveau und die Streuung der Prognosefehler haben.

7.4.1. Einfluss der Kennzahlen zur Spannweite auf die Prognosegenauigkeit

Die Kennzahlen zur Spannweite aus Kapitel 5 grenzen die Vorlaufzeiten der Bestelleingänge ab. Sie beschreiben so auch den Vorlaufzeitrahmen, für den ADI-basierte Prognosemethoden geeignet sind. Abgesehen von einer Ausnahmesituation, die in den folgenden Ausführungen beschrieben wird, ist der Einsatz ADI-basierter Prognosemethoden für Vorlaufzeiten vor dem Anfangspunkt oder nach dem Endpunkt nicht vorteilhaft.

Zu Vorlaufzeiten, die den Endpunkt $K_{1,End}(t_1, t_n, \mathbf{A})$ überschreiten, sind in der Vergangenheit nie Bestellungen eingegangen. Die multiplikative und hybride Methode sind für diese Vorlaufzeiten ungeeignet. Bei der multiplikativen Methode wird der Schätzer $\hat{E}(X_{Aet_n})$ für diese Vorlaufzeiten immer 0 sein. Da dieser Schätzer allerdings im Nenner steht, ist eine Prognose hier unmöglich. Eine Regressionsgleichung für die hybride Prognosemethode kann ebenfalls nicht aufgestellt werden, da im Schätzer von $\hat{\beta}_1(D_{Aes}, D_{A0s})$, wie in Gleichung 7.2.13 beschrieben, die Varianz $\sigma(t_1, t_n, D_{Aes})^2$ im Nenner steht. Für Vorlaufzeiten, die den Endpunkt überschreiten, gilt allerdings $\sigma(t_1, t_n, D_{Aes})^2 = 0$, so dass der Schätzer nicht bestimmt werden kann.

Die additive Methode kann zu diesen Vorlaufzeiten noch nützlich sein, wenn für den zu prognostizierenden Wunschlieferzeitpunkt erstmalig Bestellungen mit einer Vorlaufzeit vorliegen, die den Endpunkt überschreiten. $\hat{E}(U_{Aet_n})$ entspricht in dieser Situation dem Schätzer für die tatsächliche Nachfrage $\hat{E}(D_{A0t_n})$, weil diese in der Vergangenheit zu dieser Vorlaufzeit immer noch vollständig ausstehend war. Die vorliegende Bestellmenge wird mit $\hat{E}(U_{Aet_n})$ für die Prognose addiert. Liegen allerdings noch keine Bestellungen vor, bringt die additive Methode keinen zusätzlichen Nutzen gegenüber den gewöhnlichen Prognosemethoden aus der Zeitreihenanalyse, weil die Prognosen einfach nur dem Schätzer $\hat{E}(U_{Aet_n})$ bzw. $\hat{E}(D_{A0t_n})$ entsprechen.

Für Vorlaufzeiten, die den Anfangspunkt $K_{1,Start}(t_1, t_n, \mathbf{A})$ unterschreiten, sind theoretisch keine Prognosen mehr durchzuführen, da davon ausgegangen werden kann, dass die gesamte Nachfrage bereits in Form von Bestellungen vorliegt. Diese Vorgehensweise

impliziert allerdings, dass auch diesmal in der verbleibenden Vorlaufzeit keine Bestellungen mehr eingehen werden. Wenn hier eine Prognose erstellt werden soll, sind die ADI-basierten Methoden aber ungeeignet. Alle ADI-basierten Methoden liefern die gleiche Prognose, nämlich dass die vorliegende Bestellmenge D_{Aes} der tatsächlichen Nachfrage D_{A0s} entspricht.¹⁵

Die Kennzahlen zur Spannweite grenzen also den Vorlaufzeitrahmen ein, für den ADI-basierte Methoden geeignet sind. Die Kennzahl $K_{1,Range}(t_1, t_n, \mathbf{A})$ gibt die Länge dieses Zeitrahmens an. Alternativ können auch die Parameterwerte μ und σ aus dem in Kapitel 5 vorgestellten Curve Fitting eingesetzt werden, um diesen Vorlaufzeitrahmen abzuschätzen, in dem der Einsatz ADI-basierter Prognosemethoden nützlich ist.

Diese Ergebnisse bestätigen die Ausführungen aus Kapitel 6. Hier wurden die ADI-basierten Prognosemethoden als geeignete Verfahren hervorgehoben, um vorliegende Aufträge und Prognosen für die Planung von entsprechenden Wertschöpfungsschritten zu kombinieren. Sie eignen sich nicht, wenn für einen Wertschöpfungsschritt eine rein prognosebasierte Planung durchgeführt werden muss, weil die für die Methoden notwendige ADI zu dieser Vorlaufzeit noch nicht vorliegt. Für eine rein auftragsbasierte Planung sind sie überflüssig, weil eine Prognose nicht mehr notwendig ist. In den folgenden Abschnitten wird jetzt untersucht, für welche Vorlaufzeiten in dem Zeitrahmen zwischen Anfangs- und Endpunkt genauere Prognosen von den ADI-basierten gegenüber den konventionellen Methoden zu erwarten sind.

7.4.2. Einfluss der Kennzahlen zur Streuung auf die Prognosegenauigkeit

Im Kapitel 5 wurden vorlaufzeitübergreifende Kennzahlen zur durchschnittlichen Streuung des Bestellverhaltens abgeleitet. Ebenfalls wurden Kennzahlen bestimmt, die es ermöglichen, die Form dieser Streuung zu bewerten. Zusätzlich wurden in Abschnitt 7.3.2 für drei ADI-basierte Prognosemethoden sowie zwei Methoden aus der klassischen Zeitreihentheorie Kennzahlen abgeleitet, die eine Abschätzung der zu erwartenden Prognosegenauigkeit erlauben. Durch das Zusammenspiel dieser Kennzahlen kann die zu erwartende Streuung des Prognosefehlers für die verschiedenen ADI-basierten Methoden abgeschätzt werden. Die Kennzahlen zu den ADI-basierten Methoden sind dabei auf eine spezifische Vorlaufzeit e bezogen, während die Kennzahlen zur durchschnittlichen Streuung und deren Form aus dem Kapitel 5 einen vorlaufzeitübergreifenden Bezug haben. Tabelle 7.4 enthält die Kennzahlen, die für die unterschiedlichen ADI-basierten Methoden relevant sind.

Es ist zu beachten, dass die hier vorgestellten Ergebnisse auf den in Abschnitt 7.3 getroffenen Annahmen beruhen. Eine systematische Fehleinschätzung zukünftiger Werte durch die Prognosemethoden ist somit ausgeschlossen. Die Anwendung des arithmetischen Mittels als Schätzverfahren bei der multiplikativen und additiven Methode impliziert dabei gleichzeitig, dass die Zeitreihen der anteilig vorliegenden sowie ausstehenden Bestellmengen bis auf zufällige Abweichungen konstant sind. Die Kennzahlen zur Streuung aus dem

¹⁵Der Schätzer der multiplikativen Methode $\hat{E}(X_{Aet_n})$ ist hier immer 100%, bei der additiven Methode ist immer $\hat{E}(U_{Aet_n}) = 0$ und bei der hybriden Methode $\hat{\beta}_0(D_{Aes}, D_{A0s}) = 0$ und $\hat{\beta}_1(D_{Aes}, D_{A0s}) = 1$. Entsprechend gilt bei allen drei Prognosemethoden: $DF_{Aes} = D_{Aes}$.

Kapitel 5, die ebenfalls auf arithmetischen Mitteln und Standardabweichungen basieren, ermöglichen eine vorlaufzeitübergreifende Charakterisierung des Bestellverhaltens. Die Zusammenführung der Kennzahlen setzt damit voraus, dass die getroffenen Annahmen vorlaufzeitübergreifend gültig sind. Sind die Annahmen für einzelne Vorlaufzeiten verletzt, dann sind die folgenden Ausführungen auf diese Vorlaufzeiten nicht übertragbar.

	<i>Kennzahlen zur</i>	
	<i>Durchschnittsstreuung</i>	<i>Form der Streuung</i>
Multiplikative Methode	$K_{2,VK}(t_1, t_n, X_{Aes})$	$K_{3,VK,Trend}(t_1, t_n, X_{Aes})$
Additive Methode	$K_{2,\sigma}(t_1, t_n, U_{Aes})$	$K_{3,\sigma,Trend}(t_1, t_n, U_{Aes})$
Hybride Methode	$K_{2,\sigma}(t_1, t_n, D_{Aes})$	$K_{3,\sigma,Trend}(t_1, t_n, D_{Aes})$

Tabelle 7.4.: Relevante Streuungskennzahlen für ADI-basierte Methoden

Wie in Abschnitt 7.3.2 beschrieben, ist der Variationskoeffizient $VK(t_1, t_n, X_{Aes})$ ein Maß für die zu erwartende Streuung des Prognosefehlers bei Nutzung der multiplikativen Methode für Vorhersagen mit Vorlaufzeit e . $K_{2,VK}(t_1, t_n, X_{Aes})$ gibt den dazugehörigen vorlaufzeitübergreifenden Durchschnittsvariationskoeffizienten der anteilig vorliegenden Bestellmenge an. Innerhalb des Zeitrahmens zwischen Anfangs- und Endpunkt ist er damit ein Maß für die zu erwartende durchschnittliche relative Streuung des Prognosefehlers bei der multiplikativen Methode. Analog ist $K_{2,\sigma}(t_1, t_n, U_{Aes})$ ein Maß für die durchschnittlich zu erwartende absolute Streuung des Prognosefehlers bei der additiven Methode.

Um genauer einschätzen zu können, für welche Vorlaufzeiten sich die Prognosemethoden besonders eignen, sind die Kennzahlen zur Form der Streuung nützlich. Für die multiplikative und additive Methode sind dies die Kennzahlen $K_{3,VK,Trend}(t_1, t_n, X_{Aes})$ bzw. $K_{3,\sigma,Trend}(t_1, t_n, U_{Aes})$. Sie geben einen Trend in den Variationskoeffizienten bzw. Standardabweichungen zwischen Anfangs- und Endpunkt wieder. Ein positiver Wert bedeutet, dass die Variationskoeffizienten bzw. Standardabweichungen mit zunehmender Vorlaufzeit wachsen. Entsprechend ist dann mit einer höheren relativen bzw. absoluten Streuung der Prognosefehler bei zunehmender Vorlaufzeit zu rechnen. Umgekehrt ist bei einem negativen Trend eine geringere Streuung der Prognosefehler mit zunehmender Vorlaufzeit zu erwarten. Die Höhe der Kennzahl gibt dabei die Steigung des Trends an. Je höher sie ist, umso stärker ist die Steigung und sind damit die Unterschiede in der Streuung bei kurz- und langfristigen Vorlaufzeiten.

Alternativ kann auch der MSE, der als eine Kennzahl aus dem Curve Fitting resultiert, zur Abschätzung der durchschnittlichen absoluten Streuung benutzt werden. So kann er bei einem Curve Fitting der ausstehenden Bestellmenge statt $K_{2,\sigma}(t_1, t_n, U_{Aes})$ und bei der vorliegenden Bestellmenge statt $K_{2,\sigma}(t_1, t_n, D_{Aes})$ verwendet werden.

Die Kennzahl für die hybride Methode hängt von der Stärke der Korrelation zwischen vorliegender Bestellmenge und tatsächlicher Nachfrage $R(t_1, t_n, D_{Aes}, D_{A0s})$ sowie der Streuung der tatsächlichen Nachfrage $\sigma(t_1, t_n, D_{A0s})$ ab.¹⁶ Letztere kann durch Analyse der

¹⁶Die Streuung der tatsächlichen Nachfrage $\sigma(t_1, t_n, D_{A0s})$ beeinflusst auch die beiden Kennzahlen für

beiden Kennzahlen $K_{2,\sigma}(t_1, t_n, D_{Aes})$ und $K_{3,\sigma,Trend}(t_1, t_n, D_{Aes})$ abgeschätzt werden.

7.4.3. Einfluss der Kennzahlen zur Korrelation auf die Prognosegenauigkeit

Wie am Ende des letzten Abschnitts erwähnt, ist die zu erwartende Streuung des absoluten Prognosefehlers bei der hybriden Methode unter anderem von der Stärke der Korrelation zwischen vorliegender Bestellmenge und tatsächlicher Nachfrage $R(t_1, t_n, D_{Aes}, D_{A0s})$ abhängig. In Kapitel 5 wurde die Kennzahl $K_{4,Avg}(t_1, t_n, D_{Aes})$ zur Charakterisierung der durchschnittlichen Korrelationsstärke sowie $K_{4,Trend}(t_1, t_n, D_{Aes})$ zur Beschreibung von deren Form eingeführt. Der Einfluss dieser beiden Kennzahlen auf die zu erwartende Streuung des Prognosefehlers bei der hybriden Methode wird in diesem Abschnitt analysiert.

Die Kennzahl $K_{4,Avg}(t_1, t_n, D_{Aes})$ bewertet vorlaufzeitübergreifend zwischen Anfangs- und Endpunkt die durchschnittliche Korrelationsstärke zwischen vorliegender Bestellmenge und tatsächlicher Nachfrage. Je höher diese Kennzahl ist, desto stärker war im Durchschnitt die Korrelation zwischen vorliegender Bestellmenge und tatsächlicher Nachfrage. Gleichzeitig ist die Kennzahl aus Abschnitt 7.3.2 zur Streuung des absoluten Prognosefehlers $\sigma(t_1, t_n, D_{A0s}) \cdot \sqrt{1 - R(t_1, t_n, D_{Aes}, D_{A0s})^2}$ abhängig von der Korrelationsstärke $R(t_1, t_n, D_{Aes}, D_{A0s})^2$ zwischen der zu dieser Vorlaufzeit e vorliegenden Bestellmenge und der tatsächlichen Nachfrage. Der Wert $\sigma(t_1, t_n, D_{A0s}) \cdot \sqrt{1 - K_{4,Avg}(t_1, t_n, D_{Aes})^2}$ kann entsprechend als grober Schätzer der vorlaufzeitübergreifenden durchschnittlichen Streuung des Prognosefehlers bei der hybriden Methode eingesetzt werden.

Zur Einschätzung der Unterschiede in der Korrelationsstärke bei verschiedenen Vorlaufzeiten kann die Kennzahl $K_{4,Trend}(t_1, t_n, D_{Aes})$ herangezogen werden. Sie bewertet einen möglichen Trend bei der Korrelationsstärke für unterschiedliche Vorlaufzeiten. So steigt bei einem positiven Trend die Korrelationsstärke zwischen vorliegender Bestellmenge und tatsächlicher Nachfrage mit zunehmender Vorlaufzeit. Umgekehrt sinkt die Korrelationsstärke mit zunehmender Vorlaufzeit, wenn $K_{4,Trend}(t_1, t_n, D_{Aes}) < 0$ ist und ein negativer Trend vorliegt. In dem in Kapitel 5 in Tabelle 5.7 präsentierten Beispiel liegt ein solcher negativer Trend vor. Die Korrelationsstärke sinkt entsprechend kontinuierlich von 0,93 bei einer Vorlaufzeit von 2 auf 0,26 bei einer Vorlaufzeit von 6.

Die Korrelationsstärke $R(t_1, t_n, D_{Aes}, D_{A0s})^2$ ist in der Kennzahl zur Streuung des Prognosefehlers bei der hybriden Methode mit einem negativen Vorzeichen versehen. Die zu erwartende Streuung des Prognosefehlers sinkt also, wenn die Korrelationsstärke zunimmt. Gilt also $K_{4,Trend}(t_1, t_n, D_{Aes}) > 0$ und liegt somit ein positiver Trend vor, dann steigt die Korrelationsstärke und sinkt die Streuung des Prognosefehlers mit zunehmender Vorlaufzeit. Die zu erwartende Prognosegenauigkeit bei der hybriden Methode würde in dieser Situation also mit steigender Vorlaufzeit zunehmen. Das umgekehrte Verhalten ist bei einem negativen Trend zu beobachten. Die zu erwartende Streuung des Prognosefehlers steigt allerdings nicht unbedingt proportional zu dieser Kennzahl. Grund dafür ist

die Methoden aus der klassischen Zeitreihentheorie. Bei dem Modell konstanter Nachfrage entspricht sie sogar der Kennzahl.

der nichtlineare Einfluss des Korrelationskoeffizienten $R(t_1, t_n, D_{Aes}, D_{A0s})$ auf die Kennzahl $\sigma(t_1, t_n, D_{A0s}) \cdot \sqrt{1 - R(t_1, t_n, D_{Aes}, D_{A0s})^2}$.

7.4.4. Einfluss der Kennzahlen zur Konstanz der Bestellmengen auf die Prognosegenauigkeit

Die bisherigen Ausführungen zur multiplikativen und additiven Prognosemethode beruhen auf der Annahme, dass die Zeitreihe der anteilig vorliegenden bzw. ausstehenden Bestellmenge für eine bestimmte Vorlaufzeit konstant ist. Diese Annahme impliziert, dass das arithmetische Mittel als Schätzverfahren eingesetzt werden kann, ohne zu systematischen Fehleinschätzungen zu führen. Diese Annahme ist in der Praxis leider nicht immer berechtigt. Wenn das arithmetische Mittel in einer solchen Situation trotzdem als Schätzverfahren benutzt wird, kann dies in systematischen Fehleinschätzungen resultieren, wie in Abschnitt 7.1 dargestellt wurde. Es wird deshalb in diesem Abschnitt untersucht, inwiefern diese Annahme in einer beliebigen Supply Chain möglicherweise unberechtigt und der Einsatz von Schätzverfahren, die eine Konstanz der zugrunde liegenden Zeitreihe voraussetzen, ungeeignet ist.

Wie bereits in Abschnitt 7.4.1 erläutert wurde, ist der Einsatz der multiplikativen und additiven Methode bei allen Vorlaufzeiten zwischen Anfangs- und Endpunkt möglich. Ziel der Analyse ist es nun, den Anteil an Vorlaufzeiten zwischen Anfangs- und Endpunkt zu bestimmen, die die beschriebene Annahme zur Konstanz der Zeitreihen erfüllen. Die beiden in Kapitel 5 definierten Kennzahlen $K_{5,konst}(t_1, t_n, X_{Aes})$ und $K_{5,konst}(t_1, t_n, U_{Aes})$ können hierfür eingesetzt werden.

Das Schätzverfahren bei der additiven Methode basiert auf der ausstehenden Bestellmenge. Ist die Zeitreihe der ausstehenden Bestellmengen für eine Vorlaufzeit e bis auf zufällige Abweichungen konstant, dann kann das arithmetische Mittel $\mu(t_1, t_n, U_{Aes})$ verwendet werden, um den Wert $\hat{E}(U_{Aet_n})$ für die additive Methode zu schätzen. Die Kennzahl $K_{5,konst}(t_1, t_n, U_{Aes})$ gibt nun für die ausstehende Bestellmenge ex-post den Anteil an Vorlaufzeiten zwischen Anfangs- und Endpunkt an, für die die beschriebene notwendige Konstanz der zugrunde liegenden Zeitreihe nicht ausgeschlossen werden kann. Für diesen Anteil an Vorlaufzeiten ist das arithmetische Mittel $\mu(t_1, t_n, U_{Aes})$ als Schätzer für $\hat{E}(U_{Aet_n})$ geeignet. Für die verbleibende Menge $1 - K_{5,konst}(t_1, t_n, U_{Aes})$ wurde allerdings eine Systematik identifiziert, die die Verwendung des arithmetischen Mittels ausschließt. Je höher der Wert $K_{5,konst}(t_1, t_n, U_{Aes})$ ist, desto größer ist der Anteil an Vorlaufzeiten, bei denen der Einsatz der additiven Methode mit dem arithmetischen Mittel als Schätzverfahren sinnvoll ist. Analog kann die Kennzahl $K_{5,konst}(t_1, t_n, X_{Aes})$ bei der multiplikativen Methode betrachtet werden, um den Anteil an Vorlaufzeiten zu bestimmen, bei denen das arithmetische Mittel $\mu(t_1, t_n, X_{Aes})$ als Schätzer für $\hat{E}(X_{Aet_n})$ geeignet ist.

Wenn für eine bestimmte Vorlaufzeit die Annahme zur Konstanz nicht erfüllt ist, muss ein alternatives Schätzverfahren benutzt werden. Wie bereits in Kapitel 4 erläutert, ist es dabei wichtig, ein Zeitreihenmodell zu bestimmen, das zu der zugrunde liegenden Zeitreihe passt. Unterliegt die Zeitreihe der ausstehenden Bestellmenge für eine Vorlaufzeit e beispielsweise einem Trend, dann sollte ein entsprechendes den Trend berücksichtigendes

Zeitreihenmodell benutzt werden, um $\hat{E}(U_{Aet_n})$ zu bestimmen. Die Konsequenzen einer systematischen Fehleinschätzung und deren Beseitigung durch den Einsatz alternativer Schätzverfahren werden in Kapitel 8 illustriert.

7.5. Zusammenfassung

Eine möglichst genaue Prognose zukünftiger Nachfrage ist wichtig für eine Supply Chain und deren Planungsaufgaben. Fokus in diesem Kapitel war die analytische Untersuchung des Einsatzes ADI-basierter Prognosemethoden.

Für die Untersuchung der Prognosemethoden wurden zunächst wichtige statistische Aspekte erklärt. Der Unterschied zwischen systematischen und unsystematischen Prognosefehlern wurde beschrieben. Sie werden auch als Niveau bzw. Streuung des Prognosefehlers bezeichnet. Als wichtige Kriterien zur Einschätzung der Prognosegenauigkeit wurden MSE, MAD und MAPE vorgestellt.

Dem folgte eine detaillierte Beschreibung verschiedener Prognosemethoden. Neben zwei Methoden aus der klassischen Zeitreihenanalyse wurden drei ADI-basierte Prognosemethoden erläutert: die multiplikative, additive und hybride Prognosemethode. Dabei wurden die verschiedenen Ideengrundlagen und Annahmen hinter den Methoden beschrieben. Außerdem wurden verschiedene Varianten sowie unterschiedliche Schätzverfahren erklärt, die für die Methoden veröffentlicht worden sind.

In der folgenden Analyse der ADI-basierten Prognosemethoden wurden erstmals Kennzahlen ermittelt, die als Schätzer der zu erwartenden zukünftigen Streuung des Prognosefehlers geeignet sind. Sie ermöglichen es Supply Chains, zukünftig die zu erwartende Genauigkeit der Prognosemethoden vor einer Implementierung in einem APS abzuschätzen. Wie von Haberleitner u.a. (2010) beschrieben, existieren bisher leider keine Standardsoftwaremodule, die diese Prognosemethoden enthalten. Eine Supply Chain, die die Methoden benutzen will, muss sie entsprechend implementieren. Die Methoden liefern dabei häufig, aber nicht immer sehr gute Prognosen. Es ist für eine Supply Chain deshalb von großem Nutzen, wenn sie die Erfolgsaussichten einer aufwendigen Implementierung vorab bewerten kann. Gegenüber einer Simulation der Prognosemethoden mit ex-post Daten in einem Tabellenkalkulationsprogramm o.ä. haben die Kennzahlen den Vorteil, dass sie auch ohne detailliertes Fachwissen der ADI-basierten Methoden einfach bestimmbar sind. Außerdem sind sie auch berechenbar, wenn der ex-post vorliegende Datensatz sehr klein ist, was für die Durchführung einer Simulation problematisch wäre, wie schon Küsters (2005) erläutert.

Als Schätzer des zu erwartenden absoluten Prognosefehlers wurden folgende Kennzahlen abgeleitet:

- Additive Methode: $\sigma(t_1, t_n, U_{Aes})$
- Hybride Methode: $\sigma(t_1, t_n, D_{A0s}) \cdot \sqrt{1 - R(t_1, t_n, D_{Aes}, D_{A0s})^2}$

Zusätzlich wurde für die multiplikative Methode folgender Schätzer für die zu erwartende relative Streuung bestimmt:

- Multiplikative Methode: $VK(t_1, t_n, X_{Acs})$

Im Zusammenspiel mit den Kennzahlen aus Kapitel 5 zum charakteristischen Bestellverhalten erlauben es diese Werte, die Eignung ADI-basierter Prognosemethoden für verschiedene Vorlaufzeiten abzuschätzen. Die Kennzahlen aus Kapitel 5 ermöglichen es unter anderem, den für die ADI-basierten Prognosemethoden geeigneten Vorlaufzeitrahmen abzustecken und die zu erwartende zukünftige Streuung für unterschiedliche Vorlaufzeiten abzuschätzen. Die Eignung der ADI-basierten Methoden für die Planung von Wertschöpfungsschritten, die Aufträge und Prognosen kombinieren können, wurde dabei noch einmal hervorgehoben.

Die bisherigen Ausführungen in diesem Zusammenhang waren auf die statischen Kennzahlen aus Kapitel 5 begrenzt. Ergänzend ist an dieser Stelle zu erwähnen, dass die dynamischen Kennzahlen aus Kapitel 5 eine Einschätzung der Entwicklung dieser Aspekte auch für die Prognosemethoden ermöglichen.

8. Empirische Untersuchung von Prognosemethoden

Nach der analytischen Studie der ADI-basierten Prognosemethoden ist der Schwerpunkt dieses Kapitels deren empirische Untersuchung. Dies dient dazu, die Ergebnisse aus dem vergangenen Kapitel durch Tests zu untermauern. Die Korrektheit der Kennzahlen zur Bewertung der ADI-basierten Prognosemethoden wird so exemplarisch bestätigt. Dem potentiellen Nutzer wird durch diese Beispiele die Anwendung der Kennzahlen demonstriert und so eine Übernahme vereinfacht.

Wie im letzten Kapitel beschrieben, basieren die Kennzahlen auf einigen Annahmen. Der Einfluss der Annahmen auf die Anwendbarkeit der Kennzahlen und alternative Vorgehensweisen zur Abschätzung der zu erwartenden Streuung werden exemplarisch in diesem Kapitel beschrieben. Diese statistischen Kriterien, die Voraussetzung für eine Eignung der Schätzverfahren und Kennzahlen sind, werden zunächst in Abschnitt 8.1 analysiert. Anschließend wird in Abschnitt 8.2 die Tauglichkeit der Methoden für die bereits in Kapitel 5 vorgestellten Praxisdatensätze getestet. Die Erkenntnisse aus diesen Analysen sollen dem Anwender die Auswahl einer ADI-basierten Prognosemethode erleichtern.

8.1. Statistische Voraussetzung für eine Eignung der Methoden

Um die statistische Eignung einer Prognosemethode in einer bestimmten Situation zu bewerten, muss der zu erwartende Prognosefehler analysiert werden. Wie bereits in Kapitel 7 erklärt, sind dabei zwei wesentliche Eigenschaften des Prognosefehlers zu untersuchen: sein Niveau und seine Streuung. Diese beiden Eigenschaften des Prognosefehlers werden hier getrennt betrachtet.

Das Niveau des Prognosefehlers beschreibt einen systematischen Fehler in den erzeugten Vorhersagen. Es ist direkt mit dem für die Prognosemethode verwendeten Schätzverfahren verbunden. Einem solchen Schätzverfahren liegen immer Annahmen zugrunde. Bei dem Modell einer konstanten Nachfrage wird beispielsweise angenommen, dass die zugrunde liegende Zeitreihe bis auf zufällige Abweichungen konstant ist. Ist diese Annahme nicht erfüllt, beispielsweise weil die Zeitreihe einen Trend aufweist, dann resultiert aus der Anwendung des Schätzverfahrens eine systematische Fehleinschätzung. Dieses wird hier zunächst in Abschnitt 8.1.1 analysiert.

Der verbleibende Prognosefehler bei Nutzung eines Schätzverfahrens ohne systematische Fehleinschätzungen ist die Streuung. Diese Abweichungen der Prognose von den tatsächlichen Werten sind zufällig und identisch unabhängig verteilt. Sie werden anschließend




Abbildung 8.1.: Beispiel: Konstanz der anteilig vorliegenden Bestellmenge

in Abschnitt 8.1.2 untersucht. Eine besondere Problematik, die bei der multiplikativen Methode auftreten und zu extremen Fehleinschätzungen führen kann, wird in Abschnitt 8.1.3 analysiert.

8.1.1. Wahl des korrekten Schätzverfahrens

Wie bereits in Kapitel 7 gezeigt, können verschiedene Schätzverfahren für die ADI-basierten Prognosemethoden verwendet werden. Dabei sind implizit unterschiedliche Annahmen mit den Schätzverfahren verbunden. Das arithmetische Mittel setzt beispielsweise voraus, dass die zugrunde liegende Zeitreihe bis auf zufällige identisch unabhängig verteilte Abweichungen konstant ist. Wie in diesem Abschnitt exemplarisch gezeigt wird, kann es zu systematischen Fehleinschätzungen bei den Prognosen kommen, wenn die Annahmen des jeweiligen Schätzverfahrens nicht erfüllt sind. Das Schätzverfahren muss also zur jeweiligen Zeitreihe passen. Eine Besonderheit der ADI-basierten Prognosemethoden ist dabei, dass sich die Annahmen nicht auf die Zeitreihe der tatsächlichen Gesamtnachfrage, sondern methodenabhängig auf unterschiedliche Formen der ADI mit bestimmten Vorlaufzeiten beziehen.

Abbildung 8.1 zeigt im linken Graphen zwei synthetisch erzeugte Zeitreihen. Die schwarze Zeitreihe zeigt die Entwicklung der tatsächlichen Nachfrage für einen Zeitraum von 100 Wochen. Der Erzeugung der Zeitreihe wurde ein Modell einer Zeitreihe mit Trend zugrunde gelegt, wobei zufällige identisch unabhängig verteilte Abweichungen addiert wurden. Die zweite grau dargestellte Zeitreihe zeigt die anteilig vorliegende Bestellmenge mit einer Vorlaufzeit von zwei Wochen. Es wurde bei der Erstellung dieser Zeitreihe angenommen, dass für diese Vorlaufzeit die anteilig vorliegende Bestellmenge konstant ist und sich entsprechend nicht verändert. Einzig zufällige identisch unabhängig verteilte Abweichungen wurden hinzugefügt.

Der rechte Graph zeigt den Prognosefehler bei Verwendung der multiplikativen Methode für Vorhersagen mit einer Vorlaufzeit von zwei Wochen. Als Schätzer für $\hat{E}(X_{Aet_n})$ wurde das arithmetische Mittel $\mu(t_1, t_n, X_{Aes})$ über die Werte für die vergangenen 50 Wochen gebildet. Prognosen wurden für die Wochen 52 bis 100 erstellt. Eine Systematik kann bei




Abbildung 8.2.: Beispiel: Konstanz der ausstehenden Bestellmenge

den Prognosefehlern nicht erkannt werden. Der in Kapitel 7 vorgestellte Test bestätigt die Hypothese, dass das Niveau des Prognosefehlers 0 ist. Obwohl also ein Trend in der Gesamtnachfrage vorliegt, ist kein systematischer Fehler in den Nachfrageprognosen zu erkennen. Grund dafür ist, dass die dem Schätzverfahren für $\hat{E}(X_{\text{Act}_n})$ zugrunde liegende Annahme auf die in Abbildung 8.1 grau verzeichnete Zeitreihe der anteilig vorliegenden Bestellmengen bezogen ist. Die Annahme, dass diese Zeitreihe bis auf zufällig identisch unabhängig verteilte Abweichungen konstant ist, ist erfüllt. Entsprechend sind $\hat{E}(X_{\text{Act}_n})$ durch das arithmetische Mittel und die Prognose durch die multiplikative Methode nicht systematisch falsch eingeschätzt.

Eine ähnliche Situation für die additive Methode ist in Abbildung 8.2 dargestellt. Im linken Graphen ist die gleiche Zeitreihe zur tatsächlichen Nachfrage wie in Abbildung 8.1 schwarz aufgeführt. Zusätzlich ist die mit einer Woche Vorlaufzeit ausstehende Bestellmenge grau eingezeichnet. Auch für die Erzeugung dieser Zeitreihe wurde angenommen, dass die ausstehende Menge bis auf zufällige identisch unabhängig verteilte Abweichungen konstant ist. Im rechten Graphen ist wieder der Prognosefehler bei Einsatz der additiven Methode für Vorhersagen mit einer Vorlaufzeit von einer Woche dargestellt. Auch hier wurde für den Schätzer $\hat{E}(U_{\text{Act}_n})$ das arithmetische Mittel $\mu(t_1, t_n, U_{\text{Aes}})$ über die Werte der vergangenen 50 Wochen gebildet. Eine Systematik konnte bei den Prognosefehlern nicht identifiziert werden, und der in Kapitel 7 beschriebene Test bestätigt abermals die Hypothese, dass das Niveau des Prognosefehlers 0 ist. Der Grund dafür ist der gleiche wie zuvor bei der multiplikativen Methode. Das Schätzverfahren für $\hat{E}(U_{\text{Act}_n})$ basiert auf der Zeitreihe der ausstehenden Bestellmengen, die bis auf zufällig identisch unabhängig verteilte Abweichungen konstant ist. Deshalb unterliegen weder $\hat{E}(U_{\text{Act}_n})$ noch die resultierenden Prognosen einer systematischen Fehleinschätzung.

Eine andere Situation wird in Abbildung 8.3 gezeigt. Im oberen Graphen ist schwarz wieder die Entwicklung der tatsächlichen Nachfrage dargestellt. Sie entspricht der aus den beiden vorherigen Beispielen. Zusätzlich ist grau die anteilig vorliegende Bestellmenge mit einer Vorlaufzeit von einer Woche eingefügt. Bei ihrer Erzeugung wurde wie bei der tatsächlichen Nachfrage ein Modell einer Zeitreihe mit Trend zugrunde gelegt. Zu-




Abbildung 8.3.: Beispiel: Anteilig vorliegende Bestellmenge mit Trend

fällige identisch unabhängig verteilte Abweichungen wurden zur Erstellung der Zeitreihe hinzuaddiert.

Die beiden unteren Graphen zeigen die Prognosefehler, die aus der Verwendung der multiplikativen Methode für Vorhersagen mit einer Vorlaufzeit von einer Woche resultieren. Dabei wurden unterschiedliche Verfahren benutzt, um $\hat{E}(X_{\text{Act}_n})$ zu schätzen. Der linke Graph zeigt die Prognosefehler, wenn das arithmetische Mittel über die letzten 50 Wochen gebildet wurde, um $\hat{E}(X_{\text{Act}_n})$ zu berechnen. Da die Zeitreihe der anteilig vorliegenden Bestellmengen in Abbildung 8.3 für diese Vorlaufzeit aber einen positiven Trend aufweist, unterschätzt das arithmetische Mittel den tatsächlich zu erwartenden Wert für $\hat{E}(X_{\text{Act}_n})$ systematisch. Da $\hat{E}(X_{\text{Act}_n})$ im Nenner bei der multiplikativen Methode steht, überschätzt die resultierende Prognose die tatsächliche Nachfrage oft. Der Prognosefehler ist deshalb meist negativ. Es liegt also eine systematische Überschätzung der Nachfrage vor, die durch den Test aus Kapitel 7 bestätigt wird. Das Niveau des Prognosefehlers ist nicht 0.

Grund für die systematische Abweichung ist der Einsatz eines Schätzverfahrens, das für die zugrunde liegende Zeitreihe – in diesem Beispiel die anteilig vorliegende Bestellmenge mit einer Vorlaufzeit von einer Woche – nicht geeignet ist. Um diese Systematik der Prognosefehler zu beseitigen, muss ein Schätzverfahren für $\hat{E}(X_{\text{Act}_n})$ verwendet werden, das den Trend berücksichtigt. Ein solches Schätzverfahren für $\hat{E}(X_{\text{Act}_n})$ wird entsprechend

den Ausführungen aus Kapitel 4 in den Gleichungen 8.1.1 bis 8.1.3 beschrieben:

$$\hat{E}(X_{\text{Aet}_n}) = \hat{\beta}_0 + \hat{\beta}_1 \cdot (t_n + e) \quad (8.1.1)$$

$$\hat{\beta}_0 = \frac{\sum_{i=1}^n t_i^2 \sum_{i=1}^n X_{\text{Aet}_i} - \sum_{i=1}^n t_i \sum_{i=1}^n t_i \cdot X_{\text{Aet}_i}}{n \sum_{i=1}^n t_i^2 - \left(\sum_{i=1}^n t_i \right)^2} \quad (8.1.2)$$

$$\hat{\beta}_1 = \frac{n \sum_{i=1}^n t_i \cdot X_{\text{Aet}_i} - \sum_{i=1}^n t_i \sum_{i=1}^n X_{\text{Aet}_i}}{n \sum_{i=1}^n t_i^2 - \left(\sum_{i=1}^n t_i \right)^2} \quad (8.1.3)$$

Wird dieses Schätzverfahren statt des arithmetischen Mittels eingesetzt, so wird $\hat{E}(X_{\text{Aet}_n})$ nicht systematisch falsch eingeschätzt. Der resultierende Prognosefehler für dieses Schätzverfahren ist in Abbildung 8.3 im rechten Graphen illustriert. Es ist keine systematische Fehleinschätzung mehr zu erkennen. Der Test aus Kapitel 7 bestätigt die Hypothese eines Niveaus des Prognosefehlers von 0.

Ein anderes Beispiel ist in Abbildung 8.4 für die ausstehende Bestellmenge und den damit verbundenen Schätzer der additiven Methoden $\hat{E}(U_{\text{Aet}_n})$ dargestellt. Im oberen Graphen sind wieder die tatsächliche Nachfrage und die ausstehende Bestellmenge mit einer Vorlaufzeit von zwei Wochen abgetragen. Dabei unterscheidet sich auch die Zeitreihe der tatsächlichen Nachfrage von den vorherigen Beispielen. Ihre Erzeugung basiert auf dem Modell einer konstanten Nachfrage, wobei zufällige Abweichungen hinzuaddiert wurden. Für die ausstehende Bestellmenge wurde das Modell einer Zeitreihe mit Trend benutzt. Die beiden unteren Graphen enthalten wie bereits in Abbildung 8.3 die Prognosefehler für die additive Methode bei Verwendung des arithmetischen Mittels bzw. eines Schätzers, der den Trend berücksichtigt. Im linken Graphen ist bei Einsatz des arithmetischen Mittels ein systematisch positiver Prognosefehler zu erkennen. Er beruht auf dem positiven Trend in der Zeitreihe der ausstehenden Bestellmenge. Diese führt zu einer systematischen Unterschätzung von $\hat{E}(U_{\text{Aet}_n})$ durch das arithmetische Mittel.¹ Diese Fehleinschätzung resultiert auch in einer Unterschätzung der Nachfrage durch die additive Methode und damit einem systematisch positiven Prognosefehler.

Wird ein Schätzverfahren benutzt, das den Trend berücksichtigt, verschwindet in diesem Beispiel der beschriebene systematische Fehler. Ein solches Verfahren verwendet analog die Gleichungen 8.1.1 bis 8.1.3, wobei X_{Aet_i} durch U_{Aet_i} zu ersetzen ist. Dies wird durch den bereits erwähnten Test aus Kapitel 7 bestätigt und ist in Abbildung 8.4 rechts unten

¹Vgl. hierzu auch Abbildung 7.2 in Kapitel 7.




Abbildung 8.4.: Beispiel: Ausstehende Bestellmenge mit Trend

illustriert.

Dieses Beispiel verdeutlicht, dass die dem Schätzer zugrunde liegende Zeitreihe entscheidend ist für das einzusetzende Schätzverfahren. Die Zeitreihe der tatsächlichen Nachfrage ist für die Wahl des richtigen Schätzverfahrens ohne Bedeutung, denn obwohl die eigentliche Gesamtnachfrage dem Modell konstanter Nachfrage entspricht, führt der Einsatz des arithmetischen Mittels zu einer systematischen Fehleinschätzung. Auffällig ist der ähnliche Verlauf des Prognosefehlers in den Abbildungen 8.3 und 8.4. Der Verlauf im jeweils linken Graphen ähnelt dem Verlauf im rechten Graphen mit dem wesentlichen Unterschied, dass er etwas versetzt erscheint – in Abbildung 8.3 nach unten und in Abbildung 8.4 nach oben. Diese Versetzung kann durch das Niveau des Prognosefehlers, das in der systematischen Fehleinschätzung begründet ist, erklärt werden. Eine Überschätzung der Nachfrage führt zu einem positiven Niveau und damit zu einer Verschiebung nach oben. Umgekehrt resultiert aus der Unterschätzung eine Verschiebung nach unten. Ein Grund für den ähnlichen Verlauf der Zeitreihen ist die gleichbleibende Streuung der ausstehenden Bestellmenge unabhängig vom verwendeten Schätzverfahren.

Es ist wichtig zu beachten, dass die durch den Schätzer zu berücksichtigenden Systematiken nicht auf einen Trend begrenzt sind. Saisonalitäten, Zyklen oder verschiedene Kombinationen dieser Eigenheiten sind nur einige Beispiele für mögliche Systematiken in einer Zeitreihe. Entscheidend ist, dass ein Schätzverfahren ausgewählt wird, das jeg-

liche Systematik berücksichtigt, um eine systematische Fehleinschätzung zu vermeiden. Die entsprechenden Grundlagen zur Auswahl von Schätzverfahren wurden in Kapitel 4 beschrieben.

8.1.2. Zufällige Streuung im Bestellverhalten

Wie von Tempelmeier (2008, S. 33–36) beschrieben, sind zwei Aspekte des Prognosefehlers zu unterscheiden: das Niveau und die Streuung des Prognosefehlers. Das Niveau wird, wie bereits erläutert, durch unberücksichtigte Systematiken verursacht. Unter der Voraussetzung, dass ein jegliche Systematik beachtendes Prognoseverfahren benutzt wird und sich das Verhalten des zu prognostizierenden Werts nicht selbst systematisch verändert, ist das Niveau des Prognosefehlers 0. Es verbleibt einzig die Streuung des Prognosefehlers, die unter diesen Voraussetzungen in diesem Abschnitt untersucht wird.

Im Unterschied zum Niveau des Prognosefehlers tritt seine Streuung zufällig auf und ist im Gegensatz zu systematischen Fehlern nicht durch den Nutzer zu beeinflussen. Wenn eine Prognosemethode ausgewählt wurde, die die beschriebenen Voraussetzungen erfüllt, so sind die verbleibenden Prognosefehler zufällig und identisch unabhängig verteilt.² Die Annahme, dass keine systematischen Veränderungen des zu prognostizierenden Werts zu erwarten sind, impliziert dabei gleichzeitig, dass auch die Streuung unverändert bleibt. Die ex-post ermittelte Streuung kann also als Maß für die zukünftig zu erwartende Streuung verwendet werden.³

Da ein geringer Prognosefehler wünschenswert ist, sollte auch die Streuung möglichst klein gehalten werden. Unter den zuvor getroffenen Annahmen bedeutet dies, dass bei der Prognosemethode, die in der Vergangenheit die geringste Streuung verursachte, auch in der Zukunft die genauesten Prognosen zu erwarten sind. Diese Streuung kann unter den beschriebenen Voraussetzungen mit den in Kapitel 7 identifizierten Kennzahlen ermittelt werden. Liegt eine solche Situation vor, dann kann die Schlussfolgerung gezogen werden, dass die Prognosemethode mit der niedrigsten Kennzahl auch in Zukunft die genauesten Vorhersagen liefern wird.

Dieser Zusammenhang wird nun an dem in Abbildung 8.5 dargestellten synthetisch erzeugten Beispiel gezeigt. Die Zeitreihen im Beispiel beziehen sich auf einen Zeitrahmen von insgesamt 1000 Tagen. Bestellungen gingen dabei mit einer Vorlaufzeit von maximal 3 Tagen ein. Die kumuliert vorliegenden Bestellmengen für ein, zwei und drei Tage Vorlaufzeit sowie die tatsächliche Nachfrage werden in Abbildung 8.5 gezeigt. Für die Analyse wurde allen Zeitreihen das Modell konstanter Nachfrage bei der Erzeugung zugrunde gelegt und die zufälligen Abweichungen hinzuaddiert. Dabei erfüllen sowohl die Zeitreihen zur kumuliert und anteilig vorliegenden als auch die zur ausstehenden Bestellmenge die Annahme, dass sie bis auf zufällige Abweichungen konstant sind. So konnte

²Wären sie das nicht, so würden sie eine Systematik beinhalten, die durch das Prognoseverfahren nicht berücksichtigt wurde. Dies widerspräche aber der getroffenen Annahme, dass jegliche Systematik beachtet wurde.

³Es wird an dieser Stelle vorausgesetzt, dass für sämtliche Parameter (bspw. für eine exponentielle Glättung) geeignete Werte ausgewählt wurden, die nicht in einer höheren Streuung ohne Systematik resultieren.




Abbildung 8.5.: Beispiel: Konstante Nachfrage mit konstantem Bestellverhalten

das arithmetische Mittel als Schätzer bei der multiplikativen und additiven Methode eingesetzt werden, ohne eine systematische Fehleinschätzung zu verursachen.

Die folgende Analyse simuliert den Einsatz der verschiedenen Prognosemethoden mit diesen Daten. Es soll überprüft werden, ob die in Kapitel 7 identifizierten Kennzahlen zur Abschätzung der zu erwartenden Streuung des Prognosefehlers geeignet sind. Dafür wird die vorliegende Zeitreihe, wie von Küsters (2005) beschrieben, in eine Kalibrations- und Teststichprobe aufgeteilt. Die Kalibrationsstichprobe umfasst dabei die ersten 500 Tage und dient der Initialisierung der Methoden. Die Schätzer aller verwendeten Methoden wurden als arithmetisches Mittel bzw. die Regressionsgerade bei der hybriden Methode mit dem Verfahren aus den Gleichungen 7.2.12 und 7.2.13, das den MSE minimiert, berechnet. Die Kennzahlen aus Kapitel 7 wurden ebenfalls auf Basis der Bestellinformationen aus den ersten 500 Tagen ermittelt. Der 500. Tag markiert also rückblickend den gegenwärtigen Zeitpunkt, zu dem bestimmt werden soll, bei welcher Vorhersagemethode die geringste Streuung des Prognosefehlers zu erwarten ist. Die bereits erwähnten Kennzahlen wurden für diese Bewertung verwendet. Anschließend wurde ausgehend von dem 500. Tag ex-post die Nachfrage in der Teststichprobe mit einer Vorlaufzeit von 1–3 Tagen prognostiziert. Dabei wurden die Schätzer stets auf Basis der vergangenen 500 Tage neu berechnet und nicht exponentiell geglättet.

Tabelle 8.1 enthält sowohl die Kennzahlen, die am 500. Tag berechnet wurden, als auch

		Vorlaufzeit		
		$e = 1$	$e = 2$	$e = 3$
Multiplikative Methode	$VK(X_{Aes})$	2,1%	5,3%	2,5%
	$\sigma(ER_{Aes})$	2,0%	5,5%	2,4%
Hybride Methode	$\sigma(D_{A0s}) \cdot \sqrt{1 - R(D_{Aes}, D_{A0s})^2}$	1870	2280	2173
	$\sigma(EA_{Aes})$	1910	2220	2200
Additive Methode	$\sigma(U_{Aes})$	1913	2502	3769
	$\sigma(EA_{Aes})$	1908	2529	3774
Modell konstanter Nachfrage	$\sigma(D_{A0s})$	4972	4972	4972
	$\sigma(EA_{Aes})$	4941	4944	4943

Tabelle 8.1.: Testergebnisse zur Eignung der Kennzahlen

die jeweils passende Standardabweichung des absoluten bzw. relativen Prognosefehlers.⁴ So beträgt die Streuung der ausstehenden Bestellmenge $\sigma(t_1, t_n, U_{Aes})$ zwischen den Tagen 1 und 500 bei einer Vorlaufzeit von einem Tag 1913. Dies entspricht wiederum der erwarteten Streuung des Prognosefehlers bei Einsatz der additiven Methode für die nun folgenden 500 Tage. Die tatsächliche Streuung des Prognosefehlers $\sigma(t_1, t_n, EA_{Aes})$ beim Einsatz der additiven Methode mit einer Vorlaufzeit von einem Tag für die Tage 501 bis 1000 ist 1908.

Ob die Kennzahlen zur Einschätzung der Standardabweichung des Prognosefehlers geeignet sind, kann mit einem Test, der auf der Chi-Quadrat-Verteilung⁵ basiert, untersucht werden. Der Test wird unter anderem von McClave u.a. (2005, S. 458–462) beschrieben. Die Nullhypothese des Tests lautet $K = \sigma(t_1, t_n, EA_{Aes})^2$. Dabei entspricht K dem quadrierten Wert der jeweils relevanten Kennzahl. Im Fall der additiven Methode ist zum Beispiel $K = \sigma(t_x, t_y, U_{Aes})^2$. Die Testgröße in diesem Anwendungsbeispiel ist für den absoluten Prognosefehler $T = (n - 1) \cdot \sigma(t_1, t_n, EA_{Aes})^2 / K$. Analog kann die Testgröße für den relativen Prognosefehler definiert werden, indem EA_{Aes} durch ER_{Aes} ersetzt wird. Im Fall einer Vorlaufzeit von $e = 1$ ist die Testgröße aus obigen Beispiel für die multiplikative Methode als $T = 499 \cdot \sigma(t_{501}, t_{1000}, ER_{Aes})^2 / VK(t_1, t_{500}, X_{Aes})^2$ definiert. Sind die jeweiligen Prognosefehler annähernd normalverteilt, so ist die Testgröße χ^2 -verteilt mit $n - 1$ -Freiheitsgraden. Sei $c_{n-1, \gamma}$ der Wert, den eine χ^2 -Verteilung mit $n - 1$ -Freiheitsgraden mit einer Wahrscheinlichkeit von γ unterschreitet.⁶ Bei einem durch den Anwender bestimmten Signifikanzniveau von α muss $c_{n-1, \alpha/2} \leq T \leq c_{n-1, 1-\alpha/2}$ gelten, damit die Nullhypothese nicht verworfen werden muss. Ist also entweder $T < c_{n-1, \alpha/2}$ oder $T > c_{n-1, 1-\alpha/2}$, so ist K nicht als Schätzer des Prognosefehlers geeignet. Die Nullhypothese wird bei einem Signifikanzniveau von $\alpha = 10\%$ in keinem der oberen


⁴Die Parameter t_1 und t_n wurden in Tabelle 8.1 weglassen, um die Übersichtlichkeit zu verbessern.

⁵Von nun an als χ^2 -Verteilung bezeichnet.

⁶Der Wert $c_{n-1, \gamma}$ kann mit den verbreiteten Tabellen zur χ^2 -Verteilung einfach bestimmt werden. Vgl. dazu beispielsweise Pearson und Hartley (1976a, S. 136–137) sowie Pearson und Hartley (1976b, S. 160–169).

Beispiele verworfen. Der Test bestätigt also in allen diesen Beispielen die Eignung der Kennzahlen als Schätzer des jeweils zu erwartenden Prognosefehlers. Dabei kann auch davon ausgegangen werden, dass die relevanten Prognosefehler annähernd normalverteilt sind, da den zufällig identisch unabhängig verteilten Abweichungen in Abbildung 8.5 Normalverteilungen zugrunde gelegt wurden.

Die bisherigen Ausführungen basierten auf der Annahme, dass eine Prognosemethode verwendet wird, die jegliche Systematik der zugrunde liegenden Zeitreihe berücksichtigt. Was geschieht, wenn ein Verfahren benutzt wird, das dies nicht tut, wird in Abbildung 8.6 illustriert. Im oberen Graphen sind die betrachteten Zeitreihen dargestellt; sowohl die ausstehende Bestellmenge mit einer Vorlaufzeit von 2 Tagen als auch die tatsächliche Bestellmenge unterliegen einem positiven Trend. Die Abweichungen vom Trend sind zufällig und identisch unabhängig verteilt.



In den unteren Graphen ist wie in Abbildung 8.4 der Prognosefehler dargestellt, wenn Verfahren verwendet werden, die den Trend beachten bzw. nicht berücksichtigen. Die Gegenwart wird hier durch den Tag 50 markiert. Es sind dabei zwei unterschiedliche Abweichungen abgetragen. Für die Tage 1 bis 50 wird rückblickend die Streuung der tatsächlichen Werte um das von der additiven Methode mit einer Vorlaufzeit von zwei Wochen verwendete Zeitreihenmodell dargestellt. Diese rückblickenden Abweichungen sind als schwarze Zeitreihe eingefügt. Die Prognosefehler ab dem 50. Tag mit einer Vorlaufzeit

von 2 Tagen sind als graue Zeitreihen angefügt. Die jeweiligen Schätzverfahren werden dabei immer auf Grundlage der aktuell letzten 50 Tage neu berechnet. Die Prognose für den Tag 62 wurde beispielsweise am 60. Tag erzeugt, wobei die Prognosemethode mit den vorliegenden Werten für die Tage 11 bis 60 initialisiert wurde.

Bei Verwendung des arithmetischen Mittels im linken Graphen ist eine Systematik im Prognosefehler zu erkennen. Die rückblickenden Abweichungen weisen einen positiven Trend auf. Dies kann direkt auf den nicht berücksichtigten positiven Trend bei der ausstehenden Bestellmenge zurückgeführt werden. Die folgenden Vorhersagen unterschätzen die tatsächliche Nachfrage systematisch, was, wie in Abbildung 8.4 dargestellt, zu systematisch positiven Prognosefehlern führt. Die rückblickenden Abweichungen und die Prognosefehler unterscheiden sich also strukturell. Entsprechend sind die am Tag 50 ex-post beobachteten Abweichungen für die Tage 1 bis 50 nicht geeignet, um die zukünftig zu erwartenden Prognosefehler abzuschätzen. Analog zu den rückblickenden Abweichungen berücksichtigt die Kennzahl zur additiven Methode aus dem letzten Kapitel den Trend bei der ausstehenden Bestellmenge nicht und ist deshalb als Kennziffer zur Abschätzung des zukünftigen Prognosefehlers hier nicht geeignet.

Dies ist anders, wenn ein Schätzverfahren benutzt wird, das die Systematik der zugrunde liegenden Zeitreihe berücksichtigt. Im Beispiel in Abbildung 8.6 ist beispielsweise ein Verfahren zu verwenden, das einen Trend beachtet. Der rechte Graph zeigt die resultierenden Abweichungen für den Einsatz der additiven Prognosemethode. Die Fehler sind zufällig und identisch unabhängig verteilt. Die am Tag 50 ex-post beobachtete Streuung bei der additiven Methode ist dann als Schätzer der zu erwartenden zukünftigen Fehler geeignet. Um den zukünftigen Prognosefehler ohne eine Implementierung der Methode abzuschätzen, müsste nun analog zu dem Vorgehen in Kapitel 7 eine Kennzahl abgeleitet werden, die es erlaubt den Streuungswert ohne eine simulierte Prognose zu ermitteln. Der auf der χ^2 -Verteilung basierte Test bestätigt all diese Ergebnisse bei einem Signifikanzniveau von $\alpha = 10\%$.

Diese Beispiele illustrieren, wie die verschiedenen Kennzahlen aus Kapitel 7 zur Abschätzung der zukünftigen Streuung der Prognosefehler geeignet sind, wenn die relevanten zugrunde liegenden Zeitreihen bis auf zufällige Abweichungen konstant sind. Die Kennzahlen können dann auch zum Vergleich und zur Auswahl einer Prognosemethode herangezogen werden. Im Beispiel in Tabelle 8.1 würde der Anwender die hybride Methode auswählen, weil sie die niedrigsten Kennziffernwerte aufweist.⁷ Sie produziert danach auch die genauesten Vorhersagen. Ist die Annahme allerdings verletzt, dass die Zeitreihen bis auf zufällige Abweichungen konstant sind, dann sollten alternative Schätzverfahren eingesetzt werden. Die beschriebenen Kennzahlen eignen sich in dieser Situation nicht als Schätzer für den zukünftigen Prognosefehler.

8.1.3. Gefahr besonders hoher Prognosefehler bei multiplikativer Methode

Wie bereits beschrieben, versucht die multiplikative Methode die anteilig vorliegende Bestellmenge $\hat{E}(X_{\text{Aet}_n})$ abzuschätzen. Entsprechend dieser Abschätzung wird die vorlie-

⁷Dies beinhaltet auch die multiplikative Methode, deren relative Streuungswerte den Schluss nahelegen, dass auch ihre absolute Streuung höher als bei der hybriden Methode ist.




Abbildung 8.7.: Skalierungseinfluss bei multiplikativer Methode

gende Bestellmenge D_{Aes} mit dem Faktor $1/\hat{E}(X_{Aet_n})$ multipliziert, um die zukünftige Nachfrage zu prognostizieren. Wie in diesem Abschnitt gezeigt wird, kann dieses Vorgehen in bestimmten Situationen bereits bei kleinen Fehleinschätzungen von $\hat{E}(X_{Aet_n})$ zu relativ hohen Prognosefehlern führen. Die multiplikative Methode ist entsprechend in diesen Situationen vorsichtig zu verwenden.

Der linke Graph in Abbildung 8.7 zeigt die Höhe des Faktors $1/\hat{E}(X_{Aet_n})$ für unterschiedliche Werte von $\hat{E}(X_{Aet_n})$. Für $\hat{E}(X_{Aet_n}) = 10\%$ wird D_{Aes} so beispielsweise durch die multiplikative Methode für die Prognose verzehnfacht. Die Skalierung von D_{Aes} wird umso stärker, je kleiner $\hat{E}(X_{Aet_n})$ ist. Insbesondere für Werte unterhalb von $\hat{E}(X_{Aet_n}) = 10\%$ steigt die Skalierung sehr stark an, wie in Abbildung 8.7 gezeigt wird.

Durch diese starke Skalierung können geringfügige Fehleinschätzungen von $\hat{E}(X_{Aet_n})$ zu hohen Prognosefehlern führen. Wird beispielsweise $\hat{E}(X_{Aet_n}) = 4\%$ geschätzt, obwohl bereits 5% vorliegen, so wird D_{Aes} fälschlicherweise mit 25 statt mit 20 für die Prognose multipliziert. Eine Fehleinschätzung von nur 1% führt so zu einem relativen Prognosefehler von 25%. In Abbildung 8.7 wird im rechten Graphen entsprechend gezeigt, wie groß die relativen Prognosefehler sind, wenn $\hat{E}(X_{Aet_n})$ um 1%, 2% bzw. 4% falsch eingeschätzt wird. Wie leicht zu erkennen ist, können bereits diese geringen Fehleinschätzungen zu deutlichen relativen Prognosefehlern führen. So führt bei einer anteilig vorliegenden Bestellmenge von 10% eine 1%-ige Fehleinschätzung zu einem relativen Prognosefehler von über 10%, eine 2%-ige Fehleinschätzung zu einem relativen Prognosefehler von über 20% und analog eine 4%-ige Fehleinschätzung zu einem Fehler von über 40%. Bei geringeren anteilig vorliegenden Bestellmengen ist der entsprechende relative Prognosefehler noch größer.

Für die Planungsaufgaben einer Supply Chain sind solch substantielle Fehleinschätzungen der Nachfrage zu vermeiden. Übersteigt die Fehleinschätzung die in der Vergangenheit

beobachtete Streuung $\sigma(t_1, t_n, X_{Aes})$ nur geringfügig, so wird der relative Prognosefehler auch deutlich von dem auf Grundlage der Kennzahl für die multiplikative Methode $VK(t_1, t_n, X_{Aes})$ erwarteten Wert abweichen. Die multiplikative Methode ist deshalb bei geringen anteilig vorliegenden Bestellmengen mit der entsprechend starken Skalierung vorsichtig zu nutzen.

8.2. Eignung der Prognosemethoden bei Beispieldatensätzen

In diesem Abschnitt wird die praktische Einsetzbarkeit der multiplikativen, additiven und hybriden Prognosemethoden getestet. Dafür werden die Beispieldatensätze verwendet, die bereits in Kapitel 5 analysiert wurden. Die Untersuchung basiert auf dem Verfahren von Küsters (2005), das bereits im letzten Abschnitt vorgestellt wurde und den Datensatz in eine Kalibrations- und Teststichprobe aufteilt. Dabei umfassen die Kalibrationsstichproben folgenden Zeitrahmen:

- *FIRE*: 32 Monate (16)
- *BUILD*: 36 Wochen (16)
- *CHEM*: 181 Tage (91)
- *KEKRE*: 10 Zeitpunkte (5)

Die Länge der verbleibenden Teststichproben ist in Klammern dahinter angefügt. Es werden nun zunächst die Vorlaufzeiten abgesteckt, für die die ADI-basierten Methoden eingesetzt werden, bevor die Eignung von Schätzverfahren und die zu erwartende Streuung der Prognosefehler bestimmt wird.

Eine erste Abgrenzung des Vorlaufzeitrahmens, für die die Prognosemethoden geeignet erscheinen, erfolgt zunächst auf Basis der Kennzahlen zur Spannweite aus Kapitel 5. Im Fall der drei Praxisdatensätze wurden die entsprechenden Werte bereits in Kapitel 5 dargelegt und betragen für *FIRE* 0–6 Monate, für *BUILD* 0–13 Wochen und für *CHEM* 0–35 Tage.

Bei Betrachtung der drei Praxisdatensätze wird aber schnell ersichtlich, dass eine genaue Vorhersage in einigen Fällen mit Schwierigkeiten verbunden ist. Die den Schätzern zugrunde liegenden Zeitreihen weisen diverse Systematiken auf, die für eine genaue Prognose berücksichtigt werden müssen. Das Problem nur sporadisch vorliegender Bestellmengen bei den Praxisdatensätzen wird in Abschnitt 8.2.1 untersucht. Anschließend wird in Abschnitt 8.2.2 analysiert, welchen Einfluss Trends und Saisonalitäten in den Datensätzen auf die ADI-basierten Prognosemethoden haben. Außerdem wird gezeigt, dass bei der hybriden Methode gegebenenfalls Heteroskedastizität zu beachten ist. Der Einsatz der ADI-basierten Methoden bei dem synthetischen Datensatz von *KEKRE* wird in Abschnitt 8.2.3 beschrieben.

8.2.1. Problematik bei sporadisch vorliegenden Bestellmengen

Für viele der in den Datensätzen betrachteten Vorlaufzeiten ist nur sporadisch eine vorliegende Bestellung zu beobachten. Die Probleme, die diese nur sporadisch vorliegenden Bestellungen bei den verschiedenen Methoden und insbesondere den verwendeten Schätzverfahren verursachen können, werden in diesem Abschnitt untersucht. Da insbesondere bei dem Datensatz *CHEM* für viele Vorlaufzeiten nur sporadische Bestellmengen zu beobachten sind, wird er hier exemplarisch analysiert.

Abbildung 8.8 zeigt den Anteil an Wunschliefzeitpunkten im *CHEM*-Datensatz, für die mit einer bestimmten Vorlaufzeit bereits Bestellungen eingegangen sind. So liegen beispielsweise mit einer Vorlaufzeit von zwei Tagen zu ungefähr 50% der Fälle bereits Bestellungen vor. Direkt unter den verschiedenen Vorlaufzeiten sind MSE, MAD und MAPE für die Vorhersagen in der Teststichprobe aufgeführt. Es ist sofort ersichtlich, dass einzig bei einer Vorlaufzeit von einem Tag mit den ADI-basierten Methoden akzeptable Ergebnisse erzielt werden.⁸ Die niedrigste MAD bei Vorlaufzeiten von mehr als einem Tag erzeugt die hybride Methode bei einer Vorlaufzeit von zwei Tagen mit ungefähr 1,012 Millionen.⁹ Nicht aufgeführt in Abbildung 8.8 ist die durchschnittliche tatsächliche Nachfrage, die bei *CHEM* bei ungefähr 1,7 Millionen liegt. Der durchschnittliche absolute Prognosefehler beträgt also deutlich mehr als 50% der durchschnittlichen tatsächlichen Nachfrage. Der besonders hohe MAPE bei hybrider und additiver Methode sowie dem Zeitreihenmodell mit Trend resultiert aus Prognosefehlern für einige wenige Wunschliefzeitpunkte, bei denen eine verhältnismäßig geringe tatsächliche Nachfrage aufgetreten ist. Überschätzungen der Nachfrage führen hier zu teilweise extrem hohen relativen Prognosefehlern. Die Gründe, die zu diesen hohen Prognosefehlern führen, sind für die verschiedenen Methoden unterschiedlich.

Die multiplikative Methode, deren absolute Abweichungen für diese Vorlaufzeiten am höchsten sind, prognostiziert beispielsweise ausschließlich eine Nachfrage, die nicht 0 ist, wenn bereits eine Bestellung vorliegt.¹⁰ Das bedeutet hier allerdings, dass sie bei einer Vorlaufzeit von zwei Tagen in 50% der Fälle eine tatsächliche Nachfrage von 0 vorhersagt. Tatsächlich ist aber in ungefähr 88% der Fälle die Nachfrage nicht 0.¹¹ Für längere Vorlaufzeiten ist der Anteil an Prognosen, die die zukünftige Nachfrage mit 0

⁸Für die Schätzer wurde das arithmetische Mittel gebildet bzw. für die hybride Methode die Formeln 7.2.12 und 7.2.13 sowie das Zeitreihenmodell mit Trend die Gleichungen 4.1.7 und 4.1.8 verwendet. Es wurde das Zeitreihenmodell mit Trend benutzt, da ein solcher für die Zeitreihe der tatsächlichen Nachfrage mit dem entsprechenden Test nicht ausgeschlossen werden konnte.

⁹Auch eine Aggregation der Daten in der zeitlichen Dimension verbessert die Genauigkeit der Prognosen kaum. Bei genauerer Betrachtung von Abbildung 8.8 wird deutlich, dass ein Großteil der Bestellungen sehr kurzfristig eingeht. Nach einer Aggregation in der zeitlichen Dimension (beispielsweise auf Wochenbasis) verbleiben sehr wenige Bestellungen, die überhaupt mit Vorlaufzeit (im Beispielfall also einer Woche oder mehr) eingehen und für die ADI-basierten Prognosemethoden berücksichtigt werden können.

¹⁰Falls die kumuliert vorliegende Bestellmenge $D_{Aes} = 0$ ist, gilt bei der multiplikativen Methode immer $DF_{Aes} = D_{Aes} / \hat{E}(X_{Ae(s-e)}) = 0$

¹¹Für $\sim 12\%$ der Wunschliefzeitpunkte beträgt die tatsächliche Nachfrage 0, weshalb in Abbildung 8.8 auch für eine Vorlaufzeit von 0 der Anteil der Wunschliefzeitpunkte mit vorliegender Bestellmenge nicht 100% ist.

angeben, noch höher. Die tatsächliche Nachfrage wird also in all diesen Fällen deutlich unterschätzt. Gleichzeitig führt diese Unterschätzung zu einer Überschätzung in den Fällen, wenn Nachfrage vorhanden ist. Grund dafür ist die Verwendung des arithmetischen Mittels als Schätzer. In allen Fällen, in denen noch keine Bestellmengen vorliegen, die spätere Nachfrage allerdings nicht 0 ist, beträgt die anteilig vorliegende Bestellmenge $X_{Aes}=0\%$. Da X_{Aes} in das arithmetische Mittel einfließt, senkt es so gleichzeitig den Wert des Schätzers $\hat{E}(X_{Aet_n})$. In den Fällen, in denen Bestellungen zur Vorlaufzeit e vorliegen, ist $\hat{E}(X_{Aet_n})$ nun aber häufig zu niedrig angesetzt. Die resultierende Vorhersage durch die multiplikative Methode überschätzt dann die tatsächliche Nachfrage.




Abbildung 8.8.: Anteil Wunschlieferzeitpunkte mit vorliegender Bestellmenge und Prognosefehler beim *CHEM*-Datensatz für unterschiedliche Vorlaufzeiten

Im Fall der hybriden Methode entspricht die Vorhersage dem geschätzten y-Achsenabschnitt $\hat{\beta}_0(D_{Aes}, D_{A0s})$, solange keine Kundenbestellungen vorliegen.¹² Wenn die spätere Nachfrage nicht 0 ist, ist in Abhängigkeit von der Steigung der Regressionsgleichung $\hat{\beta}_1(D_{Aes}, D_{A0s})$ eine entsprechend starke Unter- bzw. Überschätzung der Nachfrage zu erwarten.

Die hohen Prognosefehler bei der additiven Methode basieren nicht auf den nur spora-

¹²Falls die kumuliert vorliegende Bestellmenge $D_{Aes} = 0$ ist, gilt bei der hybriden Methode immer $DF_{Aes} = \hat{\beta}_0(D_{Aes}, D_{A0s}) + \hat{\beta}_1(D_{Aes}, D_{A0s}) \cdot D_{Aes} = \hat{\beta}_0(D_{Aes}, D_{A0s})$.

disch vorliegenden Bestellungen bei Vorlaufzeiten von zwei und mehr Tagen. Vielmehr ist der Grund dafür das Schätzverfahren für $\hat{E}(U_{Aet_n})$ in der additiven Methode, das auf der ausstehenden Bestellmenge beruht. Diese Zeitreihen weisen für Vorlaufzeiten von mindestens zwei Tagen in über 80% der Fälle noch ausstehende Bestellmengen auf. Das Problem ist dann die Streuung in diesen Zeitreihen. Bereits die in der Kalibrationsstichprobe beobachteten Standardabweichungen $\sigma(t_1, t_n, U_{Aes})$ als Kennzahlen der additiven Methode, die in Abhängigkeit von der Vorlaufzeit zwischen 1,09 und 1,15 Millionen betragen, lassen diese Streuung der Prognosefehler erwarten. Das Gleiche gilt auch für die Prognosen, die auf dem Zeitreihenmodell mit Trend beruhen. Die ex-post berechnete Kennzahl aus Kapitel 7 zum Zeitreihenmodell mit Trend beträgt ungefähr 1,08 Millionen und deutet auch auf diese Streuung hin. Dieser Zusammenhang zwischen ex-post ermittelter Kennzahl und der Streuung der Prognosefehler wird bei beiden Methoden auch durch den im letzten Abschnitt dargestellten auf der χ^2 -Verteilung basierten Test bei einem Signifikanzniveau von $\alpha = 10\%$ bestätigt.

Wie der Tabelle in Abbildung 8.8 leicht entnommen werden kann, ist das Zeitreihenmodell mit Trend für Vorlaufzeiten von zwei und mehr Tagen am besten geeignet. Der MAD ist im Vergleich hier immer am niedrigsten und bei Vorlaufzeiten von mindestens vier Tagen ist auch der MSE geringer als bei den ADI-basierten Methoden. Trotzdem sind auch bei der Zeitreihe mit Trend die Prognosefehler extrem hoch. Grund für die hohen Prognosefehler sind neben der hohen Streuung vor allem die teilweise nur sporadisch vorliegenden Bestellungseingänge bei diesen Vorlaufzeiten. Bei der multiplikativen und hybriden Methode wird dieses sporadische Verhalten im Bestellungseingang weder im Schätzer noch in der Methode selbst berücksichtigt, was ihren Einsatz zu den entsprechenden Vorlaufzeiten ungeeignet erscheinen lässt. Bei der additiven Methode ist die besonders hohe Standardabweichung bei der ausstehenden Bestellmenge ein wesentlicher Treiber für die hohe Streuung der Prognosefehler. Bei einer Vorlaufzeit von einem Tag sind das sporadische Verhalten sowie die Streuung bei den Bestellmengen deutlich niedriger. Das arithmetische Mittel erscheint hier als Schätzer wieder geeignet. Die Prognosen mit den ADI-basierten Methoden liefern hier umgehend deutlich genauere Ergebnisse. Die ADI-basierten Methoden sowie das Zeitreihenmodell erscheinen auf Grundlage dieser Ergebnisse für einen Einsatz im *CHEM*-Beispiel allerdings größtenteils ungeeignet. Die Kennzahlen zur Konstanz der Zeitreihen, die in Kapitel 5 auch für den *CHEM*-Datensatz berechnet wurden, spiegeln dieses Ergebnis ebenfalls wider. Aufgrund des sporadischen Bedarfs, der bei diesem Datensatz zu beobachten ist, gilt hier $K_{5,konst}(t_1, t_n, D_{Aes}) = K_{5,konst}(t_1, t_n, U_{Aes}) = 0$ und $K_{5,konst}(t_1, t_n, X_{Aes}) = 18,2\%$. Es kann also für fast alle relevanten Zeitreihen ausgeschlossen werden, dass das Modell konstanter Nachfrage, das den Prognosemethoden zugrunde liegt, für deren Abbildung geeignet ist. In diesem Beispiel wäre vielmehr die Eignung spezieller Methoden, die auf die Prognose sporadischen Bedarfs spezialisiert sind und bereits auszugsweise in Kapitel 4 vorgestellt wurden, zu prüfen.

	<i>FIRE</i>	<i>BUILD</i>
Kumuliert vorliegende Bestellmenge	100%	15,4%
Ausstehende Bestellmenge	66,7%	100%
Anteilig vorliegende Bestellmenge	83,3%	15,4%

Tabelle 8.2.: Anteil Zeitreihen im für die Prognosen relevanten Vorlaufzeitrahmen mit Trend


8.2.2. Problematiken bei weiteren Besonderheiten im Bestellverhalten

Die Schätzverfahren der untersuchten ADI-basierten Prognosemethoden basieren auf der Annahme, dass die zugrunde liegenden Zeitreihen bis auf zufällige Abweichungen konstant sind. Diese Annahme ist allerdings in der Realität nicht immer erfüllt. Im letzten Abschnitt wurde gezeigt, welchen Einfluss ein sporadisches Bestellverhalten, das diese Konstanzannahme verletzt, auf die Prognosemethoden hat. Trends und Saisonalitäten sind zwei weitere Beispiele für häufiger auftretende Eigenschaften, die der Annahme einer konstanten Zeitreihe widersprechen. Der Einfluss dieser Eigenschaften sowie von Heteroskedastizität, die bereits in Kapitel 4 beschrieben wurde, bei den Praxisdatensätzen wird in diesem Abschnitt analysiert.

Zunächst wird untersucht, ob die für die Schätzverfahren relevanten Zeitreihen aus dem *FIRE*- und *BUILD*-Datensatz einen Trend aufweisen. Wie bereits dargelegt, gehen bei dem *FIRE*-Datensatz Bestellungen mit Vorlaufzeiten zwischen einem und sechs Monaten ein. Für diese Vorlaufzeiten können entsprechend die ADI-basierten Methoden eingesetzt werden. Tabelle 8.2 spiegelt den Anteil dieser sechs Vorlaufzeiten wider, bei denen in den Zeitreihen bereits innerhalb der Kalibrationsstichprobe ein Trend identifiziert werden konnte.¹³ Die Zeitreihe der kumuliert vorliegenden Bestellmenge weist hier beispielsweise in allen sechs Fällen ein Trend auf, weshalb der entsprechende Wert hier 100% beträgt. Bei den ausstehenden Bestellmengen unterliegen immer noch vier von sechs Zeitreihen einem Trend. Es sind die Zeitreihen zu den Vorlaufzeiten von einem bis vier Monaten. Bei der anteiligen Bestellmenge weisen die Zeitreihen bei fünf von sechs Vorlaufzeiten einen Trend auf. Einzig bei einer Vorlaufzeit von sechs Monaten konnte hier kein Trend identifiziert werden. Die analog bestimmten Werte für den Datensatz *BUILD* sind ebenfalls in der Tabelle aufgeführt. Sie sind für die kumuliert und anteilig vorliegende Bestellmenge deutlich niedriger. Für die ausstehende Bestellmenge liegt allerdings bei allen betrachteten Vorlaufzeiten ein Trend vor. Der Einsatz des arithmetischen Mittels als Schätzer ist bei diesen Praxisdatensätzen entsprechend in vielen Situationen ungeeignet, weil damit eine systematische Fehleinschätzung, wie in Abschnitt 8.1.1 beschrieben, verbunden wäre.

Für eine Vorlaufzeit von einem Monat wurde bei *FIRE* sowohl für die ausstehende als auch die anteilig vorliegende Bestellmenge ein Trend durch den erwähnten Test bestätigt. Abbildung 8.9 zeigt die Prognosefehler in der Teststichprobe beim Einsatz unterschiedli-

¹³Für diesen Nachweis wurde der bekannte Test aus Kapitel 4 bei einem Signifikanzniveau von $\alpha = 10\%$ auf die Kalibrationsstichprobe angewendet.

Abbildung 8.9.: Prognosefehler beim Einsatz unterschiedlicher Schätzverfahren bei *FIRE*

cher Schätzverfahren für $\hat{E}(X_{Aet_n})$ und $\hat{E}(U_{Aet_n})$ bei der multiplikativen bzw. additiven Methode. Zum einen wurde das arithmetische Mittel verwendet, das den Trend nicht berücksichtigt. Es ist leicht zu erkennen, dass in diesem Fall die Prognosefehler meist positiv sind. Die Prognose unterschätzt also die tatsächliche Nachfrage systematisch. Wenn allerdings ein Schätzer verwendet wird, der den Trend beachtet, dann ist eine solche systematische Fehleinschätzung nicht zu erkennen.

Tabelle 8.3 zeigt MSE, MAD und MAPE für die verschiedenen Schätzverfahren und Prognosemethoden beim *FIRE*-Datensatz für eine Vorlaufzeit von einem Monat. Beim Einsatz der Schätzverfahren, die den Trend beachten, sind die Prognosen der multiplikativen und additiven Methode genauer als bei Verwendung des arithmetischen Mittels. Es wurde das Zeitreihenmodell mit Trend zum Vergleich eingefügt. Dieses produziert genauere Ergebnisse als die beiden beschriebenen ADI-basierten Verfahren. Ein möglicher Grund ist die fehlende Beachtung weiterer Systematiken durch das verwendete Schätzverfahren. So beschreiben Haberleitner u.a. (2010), dass die kommerzielle Prognosesoftware SAS Analytics das additive Modell von Winters (1960) als für dieses Beispiel am besten geeignet auswählt, um $\hat{E}(U_{Aet_n})$ für die additive Prognosemethode abzuschätzen. Das Modell von Winters (1960) wird hier nicht im Detail erläutert, weil es im weiteren Verlauf der Arbeit nicht wieder aufgegriffen wird. Es ist allerdings hervorzuheben, dass dieses Modell sowohl Trends als auch Saisonalitäten berücksichtigt. Dies deutet darauf hin, dass die Zeitreihen zur ausstehenden Bestellmenge im *FIRE*-Datensatz möglicherweise Saisonalitäten aufweisen, die durch die bisherigen Schätzer nicht berücksichtigt werden. Der Einsatz eines Schätzers, der Saisonalitäten beachtet, könnte hier entsprechend die Prognosegenauigkeit der additiven Methode weiter verbessern.

Unabhängig davon erstellt die hybride Methode die genauesten Prognosen in diesem Beispiel. Als Schätzer wurden hier die Gleichungen 7.2.12 und 7.2.13 verwendet. Die Eignung dieser Schätzer basiert unter anderem auf der Annahme, dass keine Heteroskedastizität vorliegt, wie in Kapitel 4 erläutert. Liegt eine solche Heteroskedastizität vor, sind andere Verfahren einzusetzen, um die Regressionsgleichung abzuschätzen, wie von Ramanathan (2002, S. 355ff.) beschrieben. In diesem Beispiel konnte aber mit dem von Ramanathan

Methode	Schätzverfahren	MSE*	MAD	MAPE
Multiplikative Methode	Arithmetisches Mittel	2609	1314	14%
	Trend beachtet	974	824	9%
Additive Methode	Arithmetisches Mittel	1678	1059	11%
	Trend beachtet	904	783	8%
Hybride Methode		452	471	5%
Zeitreihenmodell mit Trend		860	694	7%

* in 000

Tabelle 8.3.: Standardmaße der Prognosefehler bei *FIRE*

(2002, S. 352–353) beschriebenen Goldfeld-Quandt Test bei einem Signifikanzniveau von $\alpha = 10\%$ keine Heteroskedastizität nachgewiesen werden.¹⁴ Das Schätzverfahren scheint also hier geeignet zu sein.

Die Situation ist ähnlich beim *BUILD*-Datensatz für Vorlaufzeiten von einer Woche. Mit dem gleichen Test wie bei *FIRE* konnte für die beiden Zeitreihen zur anteilig vorliegenden und ausstehenden Bestellmenge ein Trend nachgewiesen werden. Entsprechend wurde als Schätzer für $\hat{E}(X_{\text{Act}_n})$ bzw. $\hat{E}(U_{\text{Act}_n})$ bei einer Vorlaufzeit von einer Woche nur das Zeitreihenmodell mit Trend verwendet. MSE, MAD und MAPE für die Prognosen in der Teststichprobe sind in Tabelle 8.4 aufgeführt.


Als Prognosemethode aus der klassischen Zeitreihenanalyse wurde wie zuvor bei der multiplikativen und additiven Methode das Zeitreihenmodell mit Trend benutzt. Der entsprechende Test hatte ebenfalls einen Trend in der Zeitreihe der tatsächlichen Nachfrage ermittelt. Diesmal wurde allerdings die tatsächliche Nachfrage direkt modelliert und nicht wie bei den beiden ADI-basierten Methoden die ausstehende bzw. anteilig vorliegende Bestellmenge. Die hohe Streuung bei Verwendung dieses Modells war dabei bereits in der Kennzahl aus Kapitel 7 zu diesem Modell zu erkennen. Die Prognosen der ADI-basierten Methoden mit einer Vorlaufzeit von einer Woche sind deutlich genauer. Bei Betrachtung des MSE, MAD und MAPE kann allerdings keine der drei ADI-basierten Methoden als eindeutig genaueste identifiziert werden. Der niedrigste MSE liegt bei der hybriden, der niedrigste MAD bei der additiven und der niedrigste MAPE bei der multiplikativen Methode vor.

Auffällig ist, dass die hybride Methode in diesem Beispiel nicht die besten Vorhersagen erstellt. Der MAD und MAPE sind deutlich höher als bei der additiven Methode. Ein möglicher Grund ist die Heteroskedastizität in der ADI. Der Goldfeld-Quandt Test bestätigt das Vorliegen von Heteroskedastizität bei einem Signifikanzniveau von $\alpha = 10\%$. Abbildung 8.10 verdeutlicht die Heteroskedastizität in diesem Beispiel. Je größer die vorliegende Bestellmenge $D_{\text{A1}s}$ ist, umso stärker wird die Streuung der tatsächlichen Nachfrage $D_{\text{A0}s}$. Wie in Kapitel 4 beschrieben, sind bei Heteroskedastizität die verwendeten Schätzer aus den Gleichungen 7.2.12 und 7.2.13 nicht mehr effizient. Alternative Verfah-

¹⁴Der Test wird hier nicht im Detail beschrieben, weil er in den weiteren Ausführungen nicht wieder aufgegriffen wird.

Methode	MSE*	MAD	MAPE
Multiplikative Methode	848	15726	9%
Additive Methode	789	14466	14%
Hybride Methode	757	17670	19%
Zeitreihenmodell mit Trend	47561	181238	246%

* in 000.000

Tabelle 8.4.: Standardmaße der Prognosefehler bei *BUILD*Abbildung 8.10.: Heteroskedastizität bei *BUILD*-Datensatz

ren zur Bestimmung der Schätzer, wie von Ramanathan (2002, S. 355ff.) dargelegt, sind in dieser Situation besser geeignet.

Die Vorhersagen, die die ADI-basierten Methoden erzeugt haben, waren meistens genauer als die von konventionellen Methoden berechneten Prognosen. So wurden hier bei den Praxisdatensätzen *BUILD* und *FIRE* die genauesten Vorhersagen von ADI-basierten Methoden erstellt. Ihr Einsatz ist deshalb in vielen Praxissituationen angebracht. Trotzdem wurden in diesem und dem vorherigen Abschnitt bei den Praxisdatensätzen *CHEM*, *BUILD* und *FIRE* unter anderem sporadisches Bestellverhalten, Trends und Heteroskedastizität identifiziert. Das arithmetische Mittel bzw. die Schätzer aus den Gleichungen 7.2.12 und 7.2.13 führen hier, wie bereits erläutert, zu systematischen Fehleinschätzungen. Um diese Fehleinschätzungen zu vermeiden und die Prognosegenauigkeit weiter zu verbessern, ist der Einsatz entsprechender Schätzverfahren bei diesen Datensätzen vor einem Einsatz zu untersuchen.

Der Einsatz der ADI-basierten Methoden wird nun noch für den bekannten synthetischen Datensatz von *KEKRE* untersucht.

8.2.3. Einsatz der Prognosemethoden beim synthetischen Datensatz

Für die Analyse des synthetischen Datensatzes von *KEKRE* werden Prognosen auf einen Vorlaufzeitrahmen von 1–3 begrenzt. Grund dafür ist die Größe des gesamten Datensatzes. Wie bereits spezifiziert, endet die Kalibrationsstichprobe zum Zeitpunkt 10. Prognosen mit längeren Vorlaufzeiten als 3 würden sich also im frühestmöglichen Fall auf den Zeitpunkt 14 beziehen. Da der Datensatz allerdings nur bis zum Zeitpunkt 15 reicht, sind maximal zwei Prognosen mit einer Vorlaufzeit von 4 möglich,¹⁵ wenn auch der Prognosefehler ex-post bestimmt werden soll. Bei längeren Vorlaufzeiten können noch weniger bzw. keine Vorhersagen errechnet werden, deren Prognosefehler anschließend ermittelt werden kann. Da zwei oder weniger Ausprägungen eines Prognosefehlers eine zu geringe Aussagekraft haben, wird auf diese Prognosen verzichtet.

Um die Einsetzbarkeit der Schätzverfahren zu überprüfen, wurde zunächst untersucht, ob die Zeitreihen, die den Schätzern für die multiplikative und additive Methode zugrunde liegen, bis auf zufällige Abweichungen konstant sind. Ein sporadisches Bestellverhalten liegt demnach im Datensatz von *KEKRE* nicht vor. Außerdem konnte im Gegensatz zu den untersuchten Praxisdatensätzen im synthetischen Datensatz von *KEKRE* in der Kalibrationsstichprobe zwischen den Zeitpunkten 1 und 10 in keiner Zeitreihe ein Trend identifiziert werden. Es wird also davon ausgegangen, dass alle Zeitreihen in diesem Datensatz bis auf zufällige Abweichungen konstant sind. Der Einsatz des arithmetischen Mittels in den entsprechenden Schätzverfahren ist demnach unproblematisch. Für die Durchführung des Goldfeld-Quandt Tests ist der Datensatz von *KEKRE* zu klein.

Die Standardmaße MSE, MAD und MAPE zu den beschriebenen Vorhersagen im *KEKRE*-Datensatz sind in Tabelle 8.5 aufgeführt. Zur Berechnung der Schätzer wurde das arithmetische Mittel gebildet bzw. bei der hybriden Methode die Gleichungen 7.2.12 und 7.2.13 verwendet. Wie bereits in den Untersuchungen in Kapitel 5 erkannt wurde, weist der Datensatz von *KEKRE* eine deutlich geringere Streuung bei der kumuliert und anteilig vorliegenden sowie ausstehenden Bestellmenge auf als die betrachteten Praxisdatensätze. Zusätzlich ist die durchschnittliche Korrelationsstärke zwischen vorliegender Bestellmenge und tatsächlicher Nachfrage höher als bei den Praxisdatensätzen. Diese Aspekte begünstigen die Prognose mit den ADI-basierten Vorhersagemethoden bei diesem Datensatz, was sich in den relativ niedrigen Streuungswerten in Tabelle 8.5 widerspiegelt. Selbst der MAPE übersteigt nicht 1,3%. Je nach Vorlaufzeit werden dabei die genauesten Prognosen von der additiven bzw. hybriden Methode erstellt. Für den Einsatz verschiedener statistischer Tests ist der Datensatz von *KEKRE* zu klein. Es liegen zu wenige Ausprägungen von Prognosefehlern vor, um beispielsweise deren Niveau oder die Eignung der Kennzahlen aus Kapitel 7 als Schätzer für die zu erwartende Streuung zu überprüfen.

Wie zuvor bei den Praxisdatensätzen wurde wieder ein Modell aus der klassischen Zeitreihenanalyse verwendet, um die tatsächlichen Nachfragemengen direkt zu modellieren und für die Prognose zu verwenden. Es wurde das Modell konstanter Nachfrage benutzt, da die entsprechenden Tests keinen Trend in der tatsächlichen Nachfrage nachweisen konn-

¹⁵Eine Prognose zum Zeitpunkt 10 bezogen auf den Zeitpunkt 14 und eine zum Zeitpunkt 11 bezogen auf den Zeitpunkt 15.

		Vorlaufzeit		
		$e = 1$	$e = 2$	$e = 3$
Multiplikative Methode	$MSE_{\mathbf{A}e}$	1,9	1,2	2,8
	$MAD_{\mathbf{A}e}$	1,1	0,8	1,3
	$MAPE_{\mathbf{A}e}$	1,1%	0,8%	1,3%
Additive Methode	$MSE_{\mathbf{A}e}$	1,4	0,7	1,8
	$MAD_{\mathbf{A}e}$	0,9	0,8	1,3
	$MAPE_{\mathbf{A}e}$	0,9%	0,8%	1,3%
Hybride Methode	$MSE_{\mathbf{A}e}$	0,7	0,4	2,8
	$MAD_{\mathbf{A}e}$	0,8	0,6	1,3
	$MAPE_{\mathbf{A}e}$	0,8%	0,6%	1,3%
Modell konstanter Nachfrage	$MSE_{\mathbf{A}e}$	10,5	10,3	10,9
	$MAD_{\mathbf{A}e}$	2,7	2,7	2,9
	$MAPE_{\mathbf{A}e}$	2,7%	2,8%	3,0%

Tabelle 8.5.: Prognoseungenauigkeit beim Datensatz von *KEKRE*

ten. Die erstellten Prognosen mit den ADI-basierten Methoden sind allerdings genauer als die Vorhersagen, die auf diesem Modell konstanter Nachfrage beruhen. Grund dafür ist unter anderem die stärkere Streuung der tatsächlichen Nachfrage im Vergleich zu den anteilig vorliegenden und ausstehenden Bestellmengen.

Es ist allerdings hervorzuheben, dass die Aussagekraft dieser Testergebnisse für die Praxis gering ist. Die zuvor betrachteten Praxisdatensätze wiesen eine deutlich höhere Streuung als der synthetische Datensatz von *KEKRE* auf. Im Gegensatz zum *KEKRE*-Datensatz konnten bei den Praxisdatensätzen in einigen Zeitreihen zusätzlich Trends und andere Systematiken identifiziert werden. Die Ergebnisse aus dem *KEKRE*-Datensatz sind entsprechend nicht repräsentativ für die untersuchten Praxisfälle. Der *KEKRE*-Datensatz erscheint primär für theoretische Untersuchungen oder die Demonstration von verschiedenen Prognoseverfahren relevant. Für einen praxisrelevanten Vergleich von ADI-basierten und konventionellen Prognosemethoden ist er allerdings eher ungeeignet.

8.3. Zusammenfassung

Die Verwendung ADI-basierter Prognosemethoden wurde in diesem Kapitel unter verschiedenen Gesichtspunkten analysiert. Dafür wurden in Abschnitt 8.1 eigens erzeugte synthetische Datensätze und in Abschnitt 8.2 die bekannten Praxisbeispiele verwendet. Die Analyseergebnisse zeigen, dass die eingesetzten ADI-basierten Prognosemethoden oft genauere Vorhersagen als konventionelle Methoden erzeugen. So wurden bei den beiden Praxisdatensätzen *FIRE* und *BUILD* von einer ADI-basierten Methode genauere Vorhersagen erstellt als von dem Zeitreihenmodell mit Trend. Der Einsatz der ADI-basierten Methoden kann in diesen Fällen also die Prognosefehler gegenüber den untersuchten konventionellen Methoden reduzieren.

Es ist hervorzuheben, dass aus statistischer Sicht der Einsatz eines geeigneten Schätzverfahrens wichtig ist, um systematische Fehleinschätzungen in den Prognosen zu vermeiden. Besonders bei den Praxisbeispielen resultiert bei einem Großteil der beobachteten Fälle der Einsatz einfacher Schätzverfahren, wie sie in der Literatur zu den ADI-basierten Prognosemethoden vorgeschlagen werden, in systematischen Fehleinschätzungen.¹⁶ Obwohl die ADI-basierten Methoden in den Beispielen bereits die genauesten Vorhersagen erzeugen, besteht also die Chance, durch den Einsatz geeigneter Schätzverfahren das Niveau des Prognosefehlers zu senken und die Genauigkeit der Vorhersagen zu verbessern. Ein solches Schätzverfahren kann wie bei Haberleitner u.a. (2010) durch kommerzielle Prognosesoftware automatisiert durchgeführt oder durch den Anwender manuell bestimmt werden.¹⁷

¹⁶Zur Literatur ADI-basierter Prognosemethoden vgl. Kapitel 7.

¹⁷Die Grundlagen für eine manuelle Auswahl des Schätzverfahrens wurden in Kapitel 4 erläutert.

9. Fazit und Ausblick

Wie im Titel hervorgehoben und in dem einleitenden Kapitel 1 dargestellt, wird in dieser Arbeit die Einsetzbarkeit der ADI für zwei Aufgabenstellungen aus dem Supply Chain Management untersucht:

1. Die Bestimmung der Entkopplungspunktposition in der Wertschöpfungskette einer Supply Chain
2. Die Beurteilung der Verwendbarkeit ADI-basierter Prognosemethoden

Die Bedeutung dieser beiden Aufgabenstellungen für das Supply Chain Management sowie deren Einfluss auf andere Planungsaufgaben werden zunächst in Kapitel 2 erläutert. Hierfür werden zu Beginn die Grundlagen des Supply Chain Managements erklärt. Es wird beschrieben, welche Rolle unterschiedliche Planungsebenen und die hierarchische Planung für das Supply Chain Management spielen. In diesem Zusammenhang wird auch die Verwendung verschiedener Aggregationsebenen in der Planung erläutert. Die Supply Chain Planning-Matrix von Rohde u.a. (2000) wird vorgestellt, die es erlaubt, die verschiedenen Planungsaufgaben einer Supply Chain zu strukturieren und deren wechselseitige Beziehungen darzustellen. Die Matrix verwendet zwei Dimensionen, um die Planungsaufgaben einer Supply Chain aufzugliedern:

1. Den Zeithorizont einer Planungsaufgabe
2. Die Relevanz der Planungsaufgabe für die unterschiedlichen Schritte eines generischen Supply Chain Prozesses, der sich in die Schritte *Beschaffung*, *Produktion*, *Distribution* und *Absatz* unterteilt

Die unterschiedlichen Planungsaufgaben, die in einer Supply Chain auftreten können, deren wesentliche Inhalte sowie Bedeutung für die Supply Chain Planung werden ebenfalls in Kapitel 2 erläutert. Diese Beschreibung der Planungsaufgaben dient als Grundlage für die folgende Einordnung der in dieser Arbeit untersuchten Themen.

Die Bestimmung der Entkopplungspunktposition ist eines dieser Themen. Die Definition des Entkopplungspunkts als späteste Stelle in einer Wertschöpfungskette, nach der sämtliche Schritte nur noch auf Basis eines vorliegenden Auftrags durchgeführt werden, bildet die Basis für die folgende Analyse. Verschiedene in diesem Zusammenhang relevante Begriffe, wie beispielsweise die Lieferzeit, werden erklärt und klar abgegrenzt. Es werden dabei auch verschiedene in der Praxis auftretende Entkopplungspunkte wie MTO, ATO oder MTS vorgestellt. Außerdem wird das Konzept des Postponements aufgegriffen und in den Kontext eingeordnet.

Die Position des Entkopplungspunkts hat großen Einfluss auf diverse Planungsaufgaben. Sie betrifft sowohl kurzfristig operative als auch langfristig strategische Aufgaben.

Obwohl der Entkopplungspunkt für eine Supply Chain sehr wichtig ist und immensen Einfluss auf diverse Planungsaufgaben hat, existiert bisher kein Verfahren, das es ermöglicht, dessen Position ex-post in einer Wertschöpfungskette zu messen. Die explizite Bestimmung des Entkopplungspunkts in dieser Arbeit erlaubt es nun erstmals, dessen Position quantitativ zu bewerten. Dadurch ist es zum einen möglich, operative Planungsaufgaben enger auf den tatsächlich verwendeten Entkopplungspunkt abzustimmen. Zum anderen können Optimierungspotenziale identifiziert und als Grundlage für eine Repositionierung des Entkopplungspunkts im Rahmen langfristig strategischer Überlegungen genutzt werden.

Die Einbeziehung der ADI in die Bestimmung der Entkopplungspunktposition ist dabei von entscheidender Bedeutung. Die Verwendung der ADI ermöglicht es, den sukzessiven Bestellungseingang bei der Ermittlung der Entkopplungspunktposition zu berücksichtigen. Die Relevanz des sukzessiven Bestellungseingangs in diesem Zusammenhang und seine bisher mangelnde Beachtung durch das Entkopplungspunktkonzept wurden bereits von Meyr (2003) hervorgehoben. Diese Lücke wird durch die Analyse in dieser Arbeit geschlossen.

Die Prognose der zukünftigen Nachfrage ist eine andere wichtige Planungsaufgabe für eine Supply Chain, bei der auch ADI eingesetzt werden können. Teil des Prozesses zur Erstellung der Nachfrageprognosen sind statistische Prognosemethoden. Hierfür wurden einige Methoden entwickelt, die die ADI in die Vorhersage miteinbeziehen. Exemplarisch seien hier die Methoden von Bestwick (1975), Kekre u.a. (1990) oder Guerrero und Elizondo (1997) genannt. Wie von Haberleitner u.a. (2010) dargestellt, können diese ADI-basierten Prognosemethoden in bestimmten Situationen genauere Vorhersagen als manche konventionelle Methode liefern. Insbesondere bei abrupten Veränderungen der Nachfrage sind die von den ADI-basierten Methoden erzeugten Prognosen häufig exakter. Grund dafür ist die Berücksichtigung der ADI bei der Vorhersage, in der die Nachfrageveränderung oft frühzeitig reflektiert wird. So deutet sich ein Umsatzeinbruch oft durch einen frühzeitigen Bestellungenrückgang an, der in der ADI widerspiegelt wird.

Die ADI-basierten Methoden liefern allerdings nicht immer genauere Prognosen, und es existieren auch Situationen, in denen die konventionellen Methoden exaktere Vorhersagen erstellen. Die Analyseergebnisse aus dieser Arbeit ermöglichen einer Supply Chain nun erstmals, die zu erwartende Genauigkeit der ADI-basierten Prognosemethoden in bestimmten Situationen vorab zu bewerten, ohne die Methoden dafür zu implementieren. Dies ist vor allem vor dem von Haberleitner u.a. (2010) beschriebenen Hintergrund interessant, dass bisher keine standardisierten Software-Module für die ADI-basierten Methoden existieren. Eine Supply Chain, die diese Methoden nutzen will, muss sie entsprechend eigenständig implementieren. Den damit verbundenen Aufwand möchte sie natürlich nur eingehen, wenn dadurch die Genauigkeit der erzeugten Prognosen signifikant verbessert werden kann.

Grundlage für die beschriebenen Analysen ist die strukturierte ex-post Erfassung der ADI. Das in Kapitel 3 eingeführte verallgemeinerte Auftragsprofil gewährleistet diese Erfassung. Es basiert auf dem von Meyr (2003) vorgestellten Auftragsprofil, erweitert dieses allerdings um einige wichtige Aspekte. So berücksichtigt das verallgemeinerte Auftragsprofil unterschiedliche Aggregationsebenen in Bezug auf die betrachteten Kunden,

Produkte und Bestellungseingangsstellen. Außerdem wird der Einfluss unterschiedlicher Aggregationsebenen in der zeitlichen Dimension beachtet.

Die durch das verallgemeinerte Auftragsprofil ex-post erfassten Bestellmengen für die Aggregationsebene A beinhalten die folgenden Werte:

d_{Aes}	Bestellmenge, die mit einer Vorlaufzeit von e zum Wunschlieferzeitpunkt s eingegangen ist
D_{Aes}	Bestellmenge, die mit einer Vorlaufzeit von e kumuliert zum Wunschlieferzeitpunkt s vorgelegen hat
U_{Aes}	Bestellmenge, die mit einer Vorlaufzeit von e zum Wunschlieferzeitpunkt s noch ausstehend war
X_{Aes}	Bestellmenge, die mit einer Vorlaufzeit von e anteilig zum Wunschlieferzeitpunkt s vorgelegen hat

Zusätzlich werden für diese Bestellmengen auch den Wunschlieferzeitpunkt übergreifende Durchschnitts- und Streuungswerte definiert. Mit diesen Werten stellt das verallgemeinerte Auftragsprofil die Grundlage für die folgende Analyse des Bestellverhaltens und die Untersuchung der zuvor beschriebenen Aufgabenstellungen dar.

Kapitel 4 präsentiert eine Übersicht relevanter statistischer Grundlagen aus der Literatur für die folgenden Analysen. Dabei werden wichtige Aspekte aus der Zeitreihen- und Regressionsanalyse erläutert. In den Ausführungen zur Zeitreihenanalyse werden unter anderem grundlegende Zeitreihenmodelle, der Einfluss von Trends, Saisonalitäten, Zyklen und sporadischem Bedarf sowie verschiedene Berechnungsverfahren und statistische Tests erklärt. Die Erörterungen zur Regressionsanalyse beinhalten eine Darstellung der einfachen linearen Regression und des Korrelationskoeffizienten. In diesem Zusammenhang wird ebenfalls die Bedeutung von Autokorrelation und Heteroskedastizität erläutert. Abschließend wird in diesem Kapitel das Curve Fitting als alternative Modellierungsmöglichkeit dargestellt, das auch zur ex-post Beschreibung des Bestellverhaltens verwendet werden kann, wie in den folgenden Kapiteln gezeigt wird.

Bevor die Verfahren zur Bestimmung der Entkopplungspunktposition und Beurteilung der ADI-basierten Prognosemethoden vorgestellt werden, wird in Kapitel 5 ein Kennzahlensystem zur ex-post Charakterisierung des Bestellverhaltens eingeführt. Die Kennzahlen beleuchten diverse Aspekte des Bestellverhaltens. Neben der Spannweite des Bestellungseingangs, dessen Grenzen durch die ex-post beobachtete minimale und maximale Vorlaufzeit markiert sind, wird die Streuung im Bestellverhalten und die Korrelationsstärke zwischen kumuliert vorliegender Bestellmenge und tatsächlicher Nachfrage durch die Kennzahlen bewertet. Die Kennzahlen erlauben eine kompakte vorlaufzeitübergreifende Charakterisierung dieser Aspekte. Das System differenziert dabei zwischen der Betrachtung eines statischen Bestellverhaltens, das sich in dem rückwirkend analysierten Zeitraum nicht verändert hat, und der Untersuchung eben solcher Veränderungen durch dynamische Kennzahlen. Es werden dabei in Kapitel 5 drei Praxisdatensätze sowie ein synthetischer Datensatz verwendet, um das Kennzahlensystem exemplarisch vorzuführen.

Es wird ebenfalls in Kapitel 5 erläutert, wie auch das Curve Fitting zur Charakterisierung des Bestellverhaltens benutzt werden kann. Dabei wird demonstriert, wie eine leicht angepasste Normalverteilungsfunktion zur Beschreibung des Bestellverhaltens verwendet werden kann. Die durch das Curve Fitting optimierten Parameterwerte erlauben eine erste Einschätzung der Spannweite und der Streuung des Bestellverhaltens, die allerdings nicht alle durch das Kennzahlensystem beleuchteten Aspekte bewertet.

Mit dem Kennzahlensystem ist es einer Supply Chain ex-post möglich, das Bestellverhalten zu analysieren. Ein vergleichbar umfassendes Kennzahlensystem zur Charakterisierung des Bestellverhaltens ist dem Autor bisher nicht bekannt. Wie die Analysen in den Kapiteln 6 bis 8 zeigen, sind die durch das Kennzahlensystem beleuchteten Aspekte sowohl für die Bestimmung der Entkopplungspunktposition als auch den Einsatz der ADI-basierten Prognosemethoden von großer Bedeutung. Die Verwendung des Kennzahlensystems ist allerdings nicht auf diese beiden Aufgaben beschränkt. Die folgende Bestimmung der Entkopplungspunktposition zeigt, wie es einer Supply Chain möglich ist, die Einsetzbarkeit der ADI als Planungsgrundlage für verschiedene Wertschöpfungsschritte zu bestimmen. Eine Charakterisierung des Bestellverhaltens durch das Kennzahlensystem kann die Planung der entsprechenden Wertschöpfungsschritte unterstützen.

Das Verfahren zur ex-post Bestimmung der Entkopplungspunktposition wird in Kapitel 6 vorgestellt. Es ist das erste Verfahren, das eine explizite ex-post Berechnung des Entkopplungspunkts in einer Wertschöpfungskette ermöglicht. Wie bereits dargestellt, sind diese Analyseergebnisse wichtige Grundlage für viele Planungsaufgaben.

In der klassischen Sichtweise trennt der Entkopplungspunkt Wertschöpfungsschritte, die rein prognose- oder auftragsbasiert geplant werden. Dass dabei der sukzessive Bestellungseingang nicht beachtet wird, ist eine Schwachstelle des klassischen Entkopplungspunktkonzepts, die bereits von Meyr (2003) kritisiert wurde. Das in Kapitel 6 eingeführte Verfahren berücksichtigt den sukzessiven Bestellungseingang und unterscheidet drei verschiedene Planungsgrundlagen für einen Wertschöpfungsschritt:

1. Eine rein auftragsbasierte Planung
2. Eine Mischform aus auftrags- und prognosebasierter Planung
3. Eine rein prognosebasierte Planung

Zur ex-post Bestimmung des Entkopplungspunkts muss für jeden Wertschöpfungsschritt ermittelt werden, welche dieser drei Planungssituationen vorlag. Nur durch diese Zuordnung aller Wertschöpfungsschritte zu einer der drei Situationen kann die Entkopplungspunktposition, die keine eindeutige Stelle in einer Wertschöpfungskette ist, identifiziert werden. Das Verfahren zur Bestimmung dieser Planungsgrundlage basiert auf dem Abgleich der beobachteten Vorlaufzeiten der Bestellungen mit den Durchlauf- und Lieferzeiten der Wertschöpfungsschritte. Alle hierfür relevanten Messwerte werden in Kapitel 6 definiert, und es wird ein Vorgehen für deren Erhebung beschrieben. Auch die Bedeutung unterschiedlicher Aggregationsebenen und Rüstfamilien für die Entkopplungspunktbestimmung wird erklärt. Das eigentliche Verfahren zur Bestimmung der unterschiedlichen Planungsgrundlagen wird detailliert erläutert, und sämtliche Schritte werden an einem fiktiven Beispiel aus der Porzellanherstellung demonstriert.

Die Analyseergebnisse ermöglichen einer Supply Chain eine bessere Abstimmung und Integration der ADI in die operativen Planungsgrundlagen. Gleichzeitig kann sie die Analyseergebnisse nutzen, um zu untersuchen, ob die tatsächlich verwendeten Planungsgrundlagen auch angemessen sind. Wie in Kapitel 6 dargestellt, können so Missstände in der Planung identifiziert und Optimierungspotenziale für eine Repositionierung des Entkopplungspunkts im Rahmen des Strategic Network Designs herausgearbeitet werden. Plant eine Supply Chain beispielsweise einen Wertschöpfungsschritt rein auftragsbasiert, obwohl eine Mischform aus auftrags- und prognosebasierter Planung geeignet wäre, kann es sein, dass eine zu kleine Menge gefertigt wird, weil der Prognoseanteil nicht berücksichtigt wurde. Eine erneute Ausführung des Wertschöpfungsschritts mit entsprechender Rüstzeit wäre dann notwendig, die bei einer Mischform aus auftrags- und prognosebasierter Planung nicht hätte durchgeführt werden müssen. Die in den letzten beiden Kapiteln untersuchten ADI-basierten Prognosemethoden ermöglichen es, Aufträge und Prognosen für die Planung entsprechend zu kombinieren.

Die Untersuchung der ADI-basierten Prognosemethoden ist auf die Kapitel 7 und 8 aufgeteilt. Kapitel 7 ist dabei auf die analytische und Kapitel 8 auf die empirische Untersuchung der Methoden fokussiert. Die Ergebnisse aus diesen Kapiteln erlauben es einer Supply Chain, die Eignung ADI-basierter Prognosemethoden ohne eine Implementierung abzuschätzen. Im Rahmen dieser Analyse werden sämtliche ADI-basierten Prognosemethoden detailliert beschrieben. Dies umfasst die multiplikative, additive und hybride Methode. Es werden dabei alle bekannten Varianten dieser Prognosemethoden erläutert. Alle notwendigen Werte sowie Annahmen zur statistischen Analyse der Prognosegenauigkeit werden in diesem Zusammenhang ebenfalls genau definiert.

In Kapitel 7 werden zunächst verschiedene Kennzahlen entwickelt, die es ermöglichen, die zukünftig zu erwartende Prognosegenauigkeit für bestimmte Versionen der ADI-basierten Methoden auf Grundlage der ex-post vorliegenden ADI und ohne eine Implementierung abzuschätzen. Für die multiplikative Methode ist dies folgender Schätzer für den zu erwartenden relativen Prognosefehler:

- Multiplikative Methode: $VK(t_1, t_n, X_{Aes})$

Bei der additiven und hybriden Methode sind es für den zu erwartenden absoluten Prognosefehler folgende Schätzer:

- Additive Methode: $\sigma(t_1, t_n, U_{Aes})$
- Hybride Methode: $\sigma(t_1, t_n, D_{A0s}) \cdot \sqrt{1 - R(t_1, t_n, D_{Aes}, D_{A0s})^2}$

Diese Kennzahlen sind eng verbunden mit unterschiedlichen Formen der Streuung bzw. der Korrelationsstärke in der ex-post betrachteten ADI. Sie sind entweder Teil des verallgemeinerten Auftragsprofils oder können leicht aus den dort erfassten Werten abgeleitet werden. Es wurden zwei vergleichbare Schätzer für die Prognosemethoden, die auf dem Modell einer konstanten Nachfrage bzw. einer Zeitreihe mit Trend basieren, ermittelt. Sie erlauben es der Supply Chain, die zu erwartende Prognosegenauigkeit der ADI-basierten mit der einiger konventioneller Prognosemethoden zu vergleichen. Für eine vorlaufzeitübergreifende Bewertung der ADI-basierten Methoden kann das Kennzahlensystem aus

Kapitel 5 eingesetzt werden. Die Bedeutung der verschiedenen Kennzahlen für die zu erwartende Prognosegenauigkeit und die daraus resultierenden Implikationen sind in Kapitel 7 beschrieben. Die Untersuchung zeigt unter anderem, dass die ADI-basierten Prognosemethoden für die Planung von Wertschöpfungsschritten geeignet sind, die vorliegende Aufträge und Prognosen kombinieren müssen.

Die Anwendung der Kennzahlen sowie der ADI-basierten Prognosemethoden wird in Kapitel 8 an verschiedenen Datensätzen demonstriert. Dabei werden unter anderem die verschiedenen Schätzverfahren der ADI-basierten Prognosemethoden beleuchtet. Die Bedeutung der Schätzverfahren für die Prognosemethoden sowie die damit verbundenen Annahmen werden detailliert untersucht. Der Einfluss von Verletzungen dieser Annahmen auf die Prognosegenauigkeit wird analysiert. Es wird dabei auch erläutert, wie die Schätzverfahren bei einer Verletzung der zugrunde liegenden Annahmen angepasst werden können, um die zu erwartende Genauigkeit der Vorhersagen zu verbessern.

Auf Grundlage der Ergebnisse dieser Arbeit kann eine Supply Chain die Einsetzbarkeit der ADI-basierten Prognosemethoden beurteilen und eine fundierte Entscheidung zu einer möglichen Implementierung treffen.

Die in dieser Arbeit vorgestellten Untersuchungen können eine Supply Chain außerdem bei der Verwendung von ADI für verschiedene Planungsaufgaben unterstützen. Zusätzlich resultieren einige spannende Fragestellungen daraus und eröffnen Räume für weitere Forschungsarbeit. Die folgenden zwei Fragestellungen sollen abschließend an dieser Stelle hervorgehoben werden:

1. Wie funktioniert die Messung der Entkopplungspunktposition praktisch im Rahmen einer Fallstudie?
2. Können weitere Kennzahlen für andere Versionen der ADI-basierten Prognosemethoden sowie weitere konventionelle Methoden entwickelt werden, um einen umfassenderen Vergleich zu ermöglichen?

Das Verfahren zur Bestimmung der Entkopplungspunktposition wurde in dieser Arbeit konzeptionell entwickelt und vorgestellt. Es konnte allerdings bisher nicht in einer Supply Chain eingesetzt und getestet werden. Die Durchführung eines entsprechenden Projekts zur Messung der Entkopplungspunktposition würde es erlauben, den Mehrwert dieses Verfahrens und die Bedeutung der Analyse für die verschiedenen operativen und strategischen Planungsaufgaben praktisch zu untersuchen und beschreiben.

Die mögliche Verbesserung der Vorhersagegenauigkeit durch ADI-basierte Prognosemethoden wurde in den Kapiteln 7 und 8 analysiert. Basierend auf den Kennzahlen kann die zu erwartende Verbesserung der Prognosegenauigkeit durch die ADI-basierten Methoden gegenüber einigen konventionellen Methoden abgeschätzt werden. Die bisher entwickelten Kennzahlen ermöglichen es, die zu erwartende Prognosegenauigkeit von drei Versionen der ADI-basierten sowie zwei einfachen Methoden aus der Zeitreihenanalyse zu bewerten und vergleichen. Die Entwicklung und Integration zusätzlicher Kennzahlen für weitere Prognosemethoden aus der Zeitreihen- und Regressionsanalyse wäre an dieser Stelle geeignet, um die zu erwartende Verbesserung der Prognosegenauigkeit umfassender zu testen. Eine erste Auswahl möglicher Methoden wird beispielsweise von Elias u.a. (2006)

vorge stellt. In diesem Zusammenhang wäre auch die Kennzahlenentwicklung für weitere Versionen der ADI-basierten Methoden, wie sie in den Kapiteln 7 und 8 vorgestellt werden, wünschenswert. Eine Supply Chain, die vor der Entscheidung steht, ob sie eine ADI-basierte Prognosemethode implementieren soll, könnte dann auf einer umfassenden Grundlage eine erste Einschätzung des zu erwartenden Mehrwerts vornehmen und so eine entsprechend strukturierte und fundierte Entscheidung treffen.

A. Beispielhafter Einsatz verschiedener Prognosemethoden

In diesem Abschnitt werden die verschiedenen Varianten der ADI-basierten Prognosemethoden, die in Abschnitt 7.2.2 vorgestellt wurden, beispielhaft eingesetzt. Es wird dabei auf das Beispiel aus Tabelle 5.13 zurückgegriffen. Es wird wie bereits im Beispiel in Abschnitt 7.2.1 davon ausgegangen, dass der aktuelle Zeitpunkt t_{12} ist und dass die Nachfrage für t_{13} bis t_{16} vorhergesagt werden soll. Allerdings wird zusätzlich bei einigen Methoden eine Entwicklung der Prognosen untersucht. Es wird also beispielsweise analysiert, wie sich die verschiedenen Schätzer der Prognosemethoden zu t_{13} entwickeln und welche Vorhersagen daraus resultieren. In Abschnitt A.1 wird die multiplikative, in Abschnitt A.2 die additive und in Abschnitt A.3 die hybride Methode benutzt. Die Darstellung umfasst Detailbeispiele, die die abschließende Berechnung einer einzelnen konkreten Prognose beschreiben, um die Verständlichkeit der teilweise komplexen Verfahren zu erhöhen.

A.1. Beispielhafter Einsatz der multiplikativen Methode

In diesem Abschnitt werden vier Varianten der multiplikativen Methode exemplarisch angewendet. Dies sind die Versionen von Bestwick (1975) sowie Bodily und Freeland (1988), die in Abschnitt 7.2.2.1 detailliert beschrieben wurden. In den Tabellen A.1 und A.2 sind zunächst die anteilig vorliegenden Bestellmengen X_{Aes} und x_{Aes} für das Beispiel aus Tabelle 5.13 aufgeführt.

X_{Aes}	<i>Wunschlieferzeitpunkt</i>							
	t_1	t_2	t_3	t_4	t_5	t_6	t_7	t_8
$e = 3$	10,0	9,5	10,5	14,3	5,0	9,5	13,6	10,0
$e = 2$	30,0	33,3	36,8	33,3	30,0	38,1	36,4	35,0
$e = 1$	75,0	71,4	73,7	76,2	70,0	71,4	72,7	75,0
$e = 0$	100	100	100	100	100	100	100	100
	t_9	t_{10}	t_{11}	t_{12}	t_{13}	t_{14}	t_{15}	t_{16}
$e = 3$	4,8	14,3	17,4	10,0	13,6	18,2	20,0	20,8
$e = 2$	38,1	33,3	43,5	40,0	45,5	40,9	48,0	54,2
$e = 1$	81,0	76,2	78,3	80,0	72,7	72,7	72,0	70,8
$e = 0$	100	100	100	100	100	100	100	100

Tabelle A.1.: Anteilig vorliegende Bestellmengen X_{Aes} zu Beispiel aus Tabelle 5.13 (in %)

x_{Aes}	<i>Wunschlieferzeitpunkt</i>							
	t_1	t_2	t_3	t_4	t_5	t_6	t_7	t_8
$e = 3$	10,0	9,5	10,5	14,3	5,0	9,5	13,6	10,0
$e = 2$	20,0	23,8	26,3	19,0	25,0	28,6	22,7	25,0
$e = 1$	45,0	38,1	36,8	42,9	40,0	33,3	36,4	40,0
$e = 0$	25,0	28,6	26,3	23,8	30,0	28,6	27,3	25,0
	t_9	t_{10}	t_{11}	t_{12}	t_{13}	t_{14}	t_{15}	t_{16}
$e = 3$	4,8	14,3	17,4	10,0	13,6	18,2	20,0	20,8
$e = 2$	33,3	19,0	26,1	30,0	31,8	22,7	28,0	33,3
$e = 1$	42,9	42,9	34,8	40,0	27,3	31,8	24,0	16,7
$e = 0$	19,0	23,8	21,7	20,0	27,3	27,3	28,0	29,2

Tabelle A.2.: Anteilig vorliegende Bestellmengen x_{Aes} zu Beispiel aus Tabelle 5.13 (in %)

Die benötigten Schätzer für die verschiedenen Varianten sind in Tabelle A.3 aufgelistet. Sie werden dabei für die Zeitpunkte t_{12} bis t_{15} berechnet. Der Schätzer $\hat{E}(X_{Aet_n})$ wird zum einen wie bei Bestwick (1975) als arithmetisches Mittel $\mu(t_1, t_n, X_{Aes})$ bestimmt. Er wird dabei für jeden der vier Zeitpunkte vollständig neu berechnet, wobei alle Werte von t_1 bis zum jeweils aktuellen Zeitpunkt berücksichtigt werden. In einer zweiten Variante wird er, wie von Bodily und Freeland (1988) vorgeschlagen, nach der ursprünglichen Berechnung für den Zeitpunkt t_{12} exponentiell geglättet. Dabei wird der Faktor $\alpha = 0,1$ benutzt. Analog wird der Schätzer $\hat{E}(x_{Aet_n})$ für zwei Varianten der multiplikativen Methode von Bodily und Freeland (1988) durchgängig als arithmetisches Mittel berechnet bzw. nach der ursprünglichen Berechnung exponentiell geglättet.

Exemplarisch wird hier der Einsatz der Methode für die Prognose der Nachfrage zum Zeitpunkt t_{13} mit einer Vorlaufzeit von $e = 2$ für den späteren Zeitpunkt t_{15} illustriert. Wird das arithmetische Mittel verwendet, so gilt zum Zeitpunkt t_{13} für den Schätzer $\hat{E}(X_{A2t_{13}}) = 36,4\%$ und $\hat{E}(x_{A2t_{13}}) = 25,4\%$. Für die Berechnung der arithmetischen Mittel wurden die Werte X_{A2t_1} bis $X_{A2t_{13}}$ bzw. x_{A2t_1} bis $x_{A2t_{13}}$ verwendet. Werden stattdessen nach der erstmaligen Berechnung zum Zeitpunkt t_{12} die Schätzer exponentiell geglättet, ergeben sich folgende Werte:

$$\hat{E}(X_{A2t_{13}}) = 0,9 \cdot \hat{E}(X_{A2t_{12}}) + 0,1 \cdot X_{A2t_{13}} = 0,9 \cdot 35,7\% + 0,1 \cdot 45,5\% = 36,6\%$$

$$\hat{E}(x_{A2t_{13}}) = 0,9 \cdot \hat{E}(x_{A2t_{12}}) + 0,1 \cdot x_{A2t_{13}} = 0,9 \cdot 24,9\% + 0,1 \cdot 31,8\% = 25,6\%$$

Die resultierenden Vorhersagen unter Einsatz der beiden Schätzverfahren finden sich in Tabelle A.4.

Im Beispiel soll nun die Prognose $DF_{A2t_{15}}$ ermittelt werden. Bei der Verwendung der Variante von Bestwick (1975) wird der Schätzer $\hat{E}(X_{A2t_{13}})$ als arithmetisches Mittel berechnet. Daraus resultiert die folgende Prognose:

$$DF_{A2t_{15}} = D_{A2t_{15}} / \hat{E}(X_{A2t_{13}}) = 60 / 36,4\% = 164,8$$

			t_{12}	t_{13}	t_{14}	t_{15}
Arithmetisches Mittel	$\hat{E}(X_{Aet_n})$	$e = 3$	10,7	11,0	11,5	12,1
		$e = 2$	35,7	36,4	36,7	37,5
		$e = 1$	75,1	74,9	74,7	74,6
		$e = 0$	100	100	100	100
	$\hat{E}(x_{Aet_n})$	$e = 3$	10,7	11,0	11,5	12,1
		$e = 2$	24,9	25,4	25,2	25,4
		$e = 1$	39,4	38,5	38,0	37,1
		$e = 0$	24,9	25,1	25,3	25,4
Exponentiell geglättet	$\hat{E}(X_{Aet_n})$	$e = 3$	10,7	11,0	11,7	12,6
		$e = 2$	35,7	36,6	37,1	38,2
		$e = 1$	75,1	74,8	74,6	74,4
		$e = 0$	100	100	100	100
	$\hat{E}(x_{Aet_n})$	$e = 3$	10,7	11,0	11,7	12,6
		$e = 2$	24,9	25,6	25,3	25,6
		$e = 1$	39,4	38,2	37,6	36,2
		$e = 0$	24,9	25,2	25,4	25,6

Tabelle A.3.: Schätzer für verschiedene Varianten der multiplikativen Methode (in %)

Wird die exponentielle Glättung für $\hat{E}(X_{A2t_{13}})$ verwendet, dann ergibt sich folgende Prognose:

$$DF_{A2t_{15}} = D_{A2t_{15}} / \hat{E}(X_{A2t_{13}}) = 60 / 36,6\% = 163,8$$

In der ebenfalls in Abschnitt 7.2.2.1 in Formel 7.2.10 vorgestellten Variante der multiplikativen Methode von Bodily und Freeland (1988) wird die Prognose selbst exponentiell geglättet. Für die zu erstellende Prognose gilt dabei:

$$DF_{A2t_{15}} = \alpha \cdot d_{A2t_{15}} / \hat{E}(x_{A2t_{13}}) + (1 - \alpha) \cdot DF_{A2t_{14}}$$

Für die exponentielle Glättung wird die zum vorherigen Zeitpunkt t_{12} mit einer Vorlaufzeit von ebenfalls $e = 2$ erstellte Prognose $DF_{A2t_{14}}$ für den Zeitpunkt t_{14} verwendet. Die Prognose $DF_{A2t_{14}}$ beträgt dabei 126,2 und $d_{A2t_{15}} = 35$. Wenn $\hat{E}(x_{A2t_{13}})$ mit dem arithmetischen Mittel berechnet wurde, dann resultiert daraus folgende Prognose:

$$DF_{A2t_{15}} = 0,1 \cdot 35 / 25,4\% + 0,9 \cdot 126,2 = 127,3$$

Wird $\hat{E}(x_{A2t_{13}})$ stattdessen exponentiell geglättet, dann gilt:

$$DF_{A2t_{15}} = 0,1 \cdot 35 / 25,6\% + 0,9 \cdot 126,2 = 127,3$$

Die tatsächliche Nachfrage zum Zeitpunkt t_{15} betrug nun 125. Die resultierenden absoluten und relativen Prognosefehler sind in Tabelle A.5 aufgeführt.

Bei Verwendung der beschriebenen Variante von Bestwick (1975) beträgt der absolute

DF_{Aes}			t_{13}	t_{14}	t_{15}	t_{16}
Arithm. Mittel	$\hat{E}(X_{Aet_n})$	$e = 3$			232,7	228,0
		$e = 2$		126,2	164,8	177,0
		$e = 1$	106,6	106,8	120,4	114,0
	$\hat{E}(x_{Aet_n})$	$e = 3$			232,7	232,2
		$e = 2$		126,2	127,3	130,4
		$e = 1$	106,6	105,0	102,4	97,6
Expon. geglättet	$\hat{E}(X_{Aet_n})$	$e = 3$			232,7	226,6
		$e = 2$		126,2	163,8	175,4
		$e = 1$	106,6	106,9	120,6	114,3
	$\hat{E}(x_{Aet_n})$	$e = 3$			232,7	232,1
		$e = 2$		126,2	127,3	130,3
		$e = 1$	106,6	105,1	102,5	97,8

Tabelle A.4.: Prognosen für unterschiedliche Varianten der multiplikativen Methode

Prognosefehler also $EA_{A2t_{15}} = 125 - 164,8 = -39,8$ und der relative Prognosefehler $ER_{A2t_{15}} = -39,8/125 = -31,8\%$.

			EA_{Aes}				$ER_{Aes} \text{ (in \%)}$			
			t_{13}	t_{14}	t_{15}	t_{16}	t_{13}	t_{14}	t_{15}	t_{16}
Arithm. Mittel	$\hat{E}(X_{Aet_n})$	$e = 3$			-107,7	-108,0			-86,1	-90,0
		$e = 2$		-16,2	-39,8	-57,0		-14,7	-31,8	-47,5
		$e = 1$	3,4	3,2	4,6	6,0	3,1	2,9	3,7	5,0
	$\hat{E}(x_{Aet_n})$	$e = 3$			-107,7	-112,2			-86,1	-93,5
		$e = 2$		-16,2	-2,3	-10,4		-14,7	-1,9	-8,7
		$e = 1$	3,4	5,0	22,6	22,4	3,1	4,5	18,1	18,7
Expon. geglättet	$\hat{E}(X_{Aet_n})$	$e = 3$			-107,7	-106,6			-86,1	-88,8
		$e = 2$		-16,2	-38,8	-55,4		-14,7	-31,0	-46,1
		$e = 1$	3,4	3,1	4,4	5,7	3,1	2,8	3,5	4,7
	$\hat{E}(x_{Aet_n})$	$e = 3$			-107,7	-112,1			-86,1	-93,4
		$e = 2$		-16,2	-2,3	-10,3		-14,7	-1,8	-8,6
		$e = 1$	3,4	4,9	22,5	22,2	3,1	4,5	18,0	18,5

Tabelle A.5.: Prognosefehler für unterschiedliche Varianten der multiplikativen Methode

Abschließend sind in Tabelle A.6 der MSE, MAD und MAPE für die Nachfrageprognosen der Zeitpunkte t_{14} bis t_{16} mit einer Vorlaufzeit von $e = 2$ aufgelistet. Die in Gleichung 7.2.10 vorgestellte Variante von Bodily und Freeland (1988), die $\hat{E}(x_{Aet_n})$ sowie die Prognose selbst exponentiell glättet, produziert hier die genauesten Vorhersagen und hat den niedrigsten MSE, MAD und MAPE. Der MAD errechnet sich für diese Variante aus den drei Werten -16,2, -2,3 und -10,3, deren durchschnittlicher Betrag 9,6 beträgt.

Arithm. Mittel	$\hat{E}(X_{A2t_n})$	MSE_{A2}	1697
		MAD_{A2}	37,7
		$MAPE_{A2}$	31,3%
	$\hat{E}(x_{A2t_n})$	MSE_{A2}	126
		MAD_{A2}	9,7
		$MAPE_{A2}$	8,4%
Expon. geglättet	$\hat{E}(X_{A2t_n})$	MSE_{A2}	1611
		MAD_{A2}	36,8
		$MAPE_{A2}$	30,6%
	$\hat{E}(x_{A2t_n})$	MSE_{A2}	125
		MAD_{A2}	9,6
		$MAPE_{A2}$	8,4%

Tabelle A.6.: Standardmaße zur Prognoseungenauigkeit für unterschiedliche Varianten der multiplikativen Methode

A.2. Beispielhafter Einsatz der additiven Methode

In diesem Abschnitt wird der Einsatz von vier Varianten der additiven Prognosemethode am Beispiel aus Tabelle 5.13 demonstriert. Es sind dies zum einen die Version von Kekre u.a. (1990) und zum anderen die drei zusätzlichen Varianten von Guerrero und Elizondo (1997). Alle vier Versionen werden detailliert in Abschnitt 7.2.2.2 erläutert. Die für die Prognose notwendigen Werte U_{Aes} und U_{Aes}^* sind in den Tabellen A.7 und A.8 aufgeführt.

U_{Aes}	<i>Wunschlieferzeitpunkt</i>							
	t_1	t_2	t_3	t_4	t_5	t_6	t_7	t_8
$e = 3$	90	95	85	90	95	95	95	90
$e = 2$	70	70	60	70	70	65	70	65
$e = 1$	25	30	25	25	30	30	30	25
$e = 0$	0	0	0	0	0	0	0	0
	t_9	t_{10}	t_{11}	t_{12}	t_{13}	t_{14}	t_{15}	t_{16}
$e = 3$	100	90	95	90	95	90	100	95
$e = 2$	65	70	65	60	60	65	65	55
$e = 1$	20	25	25	20	30	30	35	35
$e = 0$	0	0	0	0	0	0	0	0

Tabelle A.7.: Ausstehende Bestellmengen U_{Aes} zu Beispiel aus Tabelle 5.13

In Tabelle A.9 sind zunächst die relevanten Schätzer für die verschiedenen Varianten der additiven Methode aufgelistet. Sie werden analog zur multiplikativen Methode in Abschnitt A.1 für die Zeitpunkte t_{12} bis t_{15} berechnet. Wie ursprünglich von Kekre u.a. (1990) vorgeschlagen, wird der Schätzer $\hat{E}(U_{Aet_n})$ nach seiner ursprünglichen Berechnung für den Zeitpunkt t_{12} exponentiell geglättet. Zur Initialisierung wird $\hat{E}(U_{Aet_n})$ dabei als arithmetisches Mittel für den Zeitpunkt t_{12} berechnet. $\hat{E}(U_{Aet_n})$ wird ebenfalls, wie

U_{Aes}^*	Wunschlieferzeitpunkt							
	t_1	t_2	t_3	t_4	t_5	t_6	t_7	t_8
$e = 3$	90	95	85	90	95	95	95	90
$e = 2$	80	80	70	85	75	75	85	75
$e = 1$	55	65	60	60	60	70	70	60
$e = 0$	75	75	70	80	70	75	80	75
	t_9	t_{10}	t_{11}	t_{12}	t_{13}	t_{14}	t_{15}	t_{16}
$e = 3$	100	90	95	90	95	90	100	95
$e = 2$	70	85	85	70	75	85	90	80
$e = 1$	60	60	75	60	80	75	95	100
$e = 0$	85	80	90	80	80	80	90	85

Tabelle A.8.: Ausstehende Bestellmengen U_{Aes}^* zu Beispiel aus Tabelle 5.13

von Guerrero und Elizondo (1997) vorgeschlagen, für jeden Zeitpunkt als arithmetisches Mittel $\mu(t_1, t_n, U_{\text{Aes}})$ vollständig neu bestimmt, wobei auch hier immer alle Werte seit dem Zeitpunkt t_1 berücksichtigt werden. Der Schätzer $\hat{E}(U_{\text{Aet}_n}^*)$ wird analog, wie auch von Guerrero und Elizondo (1997) beschrieben, durchgängig als arithmetische Mittel berechnet bzw. nach der ursprünglichen Berechnung exponentiell geglättet. Als Faktor für die exponentielle Glättung wird auch in diesem Abschnitt immer $\alpha = 0,1$ verwendet.

			t_{12}	t_{13}	t_{14}	t_{15}
Arithmetisches Mittel	$\hat{E}(U_{\text{Aet}_n})$	$e = 3$	92,5	92,7	92,5	93,0
		$e = 2$	66,7	66,2	66,1	66,0
		$e = 1$	25,8	26,2	26,4	27,0
		$e = 0$	0	0	0	0
	$\hat{E}(U_{\text{Aet}_n}^*)$	$e = 3$	92,5	92,7	92,5	93,0
		$e = 2$	77,9	77,7	78,2	79,0
		$e = 1$	62,9	64,2	65,0	67,0
		$e = 0$	77,9	78,1	78,2	79,0
Exponentiell geglättet	$\hat{E}(U_{\text{Aet}_n})$	$e = 3$	92,5	92,8	92,5	93,2
		$e = 2$	66,7	66,0	65,9	65,8
		$e = 1$	25,8	26,3	26,6	27,5
		$e = 0$	0	0	0	0
	$\hat{E}(U_{\text{Aet}_n}^*)$	$e = 3$	92,5	92,8	92,5	93,2
		$e = 2$	77,9	77,6	78,4	79,5
		$e = 1$	62,9	64,6	65,7	68,6
		$e = 0$	77,9	78,1	78,3	79,5

Tabelle A.9.: Schätzer für verschiedene Varianten der additiven Methode

Exemplarisch wird wieder die Prognose für den Zeitpunkt t_{15} mit einer Vorlaufzeit von $e = 2$ zum Zeitpunkt t_{13} dargestellt. Die zu bestimmenden Schätzer $\hat{E}(U_{\text{Aet}_{13}})$ und

DF_{Aes}			t_{13}	t_{14}	t_{15}	t_{16}
Arithm. Mittel	$\hat{E}(U_{Aet_n})$	$e = 3$			117,5	117,7
		$e = 2$		111,7	126,2	131,1
		$e = 1$	105,8	106,2	116,4	112,0
	$\hat{E}(U_{Aet_n}^*)$	$e = 3$			117,5	117,5
		$e = 2$		111,7	111,8	112,4
		$e = 1$	105,8	105,2	104,2	102,4
Expon. geglättet	$\hat{E}(U_{Aet_n})$	$e = 3$			117,5	117,8
		$e = 2$		111,7	126,0	130,9
		$e = 1$	105,8	106,3	116,6	112,5
	$\hat{E}(U_{Aet_n}^*)$	$e = 3$			117,5	117,5
		$e = 2$		111,7	111,8	112,4
		$e = 1$	105,8	105,2	104,3	102,7

Tabelle A.10.: Prognosen für unterschiedliche Varianten der additiven Methode

$\hat{E}(U_{A2t_{13}}^*)$ können abermals als arithmetisches Mittel oder per exponentieller Glättung berechnet werden. Für die arithmetischen Mittel werden die Werte U_{A2t_1} bis $U_{A2t_{13}}$ und $U_{A2t_1}^*$ bis $U_{A2t_{13}}^*$ betrachtet, woraus $\hat{E}(U_{A2t_{13}}) = 66,2$ bzw. $\hat{E}(U_{A2t_{13}}^*) = 77,7$ resultiert. Bei Verwendung der exponentiellen Glättung nach der erstmaligen Berechnung zum Zeitpunkt t_{12} ergeben sich folgende Werte:

$$\hat{E}(U_{A2t_{13}}) = 0,9 \cdot \hat{E}(U_{A2t_{12}}) + 0,1 \cdot U_{A2t_{13}} = 0,9 \cdot 66,7 + 0,1 \cdot 60 = 66,0$$

$$\hat{E}(U_{A2t_{13}}^*) = 0,9 \cdot \hat{E}(U_{A2t_{12}}^*) + 0,1 \cdot U_{A2t_{13}}^* = 0,9 \cdot 77,9 + 0,1 \cdot 75 = 77,6$$

In Tabelle A.10 werden nun die Prognosen gezeigt, die mit den zu den verschiedenen Schätzern passenden Methoden berechnet wurden.

Die zu bestimmende Prognose ist $DF_{A2t_{15}}$. In der ursprünglichen Version der additiven Methode von Kekre u.a. (1990) muss zur Berechnung der Vorhersage die für den Zeitpunkt t_{15} vorliegende Nachfrage $D_{A2t_{15}}$ mit dem Schätzwert $\hat{E}(U_{A2t_{13}})$ addiert werden. Zum Zeitpunkt t_{13} liegt dabei eine Nachfrage von 60 für den Wunschlieferzeitpunkt t_{15} vor. Wird $\hat{E}(U_{A2t_{13}})$ als arithmetisches Mittel geschätzt, ergibt sich folgende Nachfrageprognose:

$$DF_{A2t_{15}} = D_{A2t_{15}} + \hat{E}(U_{A2t_{13}}) = 60 + 66,2 = 126,2$$

Wird die exponentiellen Glättung eingesetzt, dann resultiert daraus stattdessen folgende Prognose:

$$DF_{A2t_{15}} = D_{A2t_{15}} + \hat{E}(U_{A2t_{13}}) = 60 + 66,0 = 126,0$$

Bei Verwendung der zweiten in Abschnitt 7.2.2.2 in Formel 7.2.11 vorgestellten Version der additiven Methode gilt folgende Gleichung für den Prognosewert:

$$DF_{A2t_{15}} = 0,1 \cdot \left(d_{Ae2t_{15}} + \hat{E}(U_{A2t_{13}}^*) \right) + 0,9 \cdot DF_{A2t_{14}}$$

Der Wert $DF_{A2t_{14}}$ entspricht dabei der letzten mit einer Vorlaufzeit von $e = 2$ erstellten Prognose für den Zeitpunkt t_{14} . Es gilt $DF_{A2t_{14}} = 111,7$. Wie bereits im letzten Abschnitt ist $d_{A2t_{15}} = 35$. Wird der Wert $\hat{E}(U_{A2t_{13}}^*)$ als arithmetisches Mittel geschätzt, dann ergibt dies folgende Prognose:

$$DF_{A2t_{15}} = 0,1 \cdot (35 + 77,7) + 0,9 \cdot 111,7 = 111,8$$

Bei Verwendung der exponentiellen Glättung für $\hat{E}(U_{A2t_{13}}^*)$ ist die Prognose fast identisch:

$$DF_{A2t_{15}} = 0,1 \cdot (35 + 77,6) + 0,9 \cdot 111,7 = 111,8$$

Die tatsächliche Nachfrage zum Zeitpunkt t_{15} betrug nun 125, woraus die folgenden in Tabelle A.11 aufgelisteten absoluten und relativen Prognosefehler resultieren. Bei Betrachtung der ursprünglichen Version der additiven Methode, die $\hat{E}(U_{A2t_{13}})$ als arithmetisches Mittel schätzt, beträgt der absolute Prognosefehler $EA_{A2t_{15}} = 125 - 126,2 = -1,2$ und der relative Prognosefehler $ER_{A2t_{15}} = -1,2/125 = -0,9\%$.

			EA_{Aes}				$ER_{Aes} \text{ (in \%)}$			
			t_{13}	t_{14}	t_{15}	t_{16}	t_{13}	t_{14}	t_{15}	t_{16}
Arithm. Mittel	$\hat{E}(U_{Aet_n})$	$e = 3$			7,5	2,3			6,0%	1,9%
		$e = 2$		-1,7	-1,2	-11,1		-1,5%	-0,9%	-9,2%
		$e = 1$	4,2	3,8	8,6	8,0	3,8%	3,5%	6,9%	6,7%
	$\hat{E}(U_{Aet_n}^*)$	$e = 3$			7,5	2,5			6,0%	2,1%
		$e = 2$		-1,7	13,2	7,6		-1,5%	10,6%	6,3%
		$e = 1$	4,2	4,8	20,8	17,6	3,8%	4,4%	16,7%	14,6%
Expon. geglättet	$\hat{E}(U_{Aet_n})$	$e = 3$			7,5	2,3			6,0%	1,9%
		$e = 2$		-1,7	-1,0	-10,9		-1,5%	-0,8%	-9,1%
		$e = 1$	4,2	3,8	8,4	7,5	3,8%	3,4%	6,7%	6,3%
	$\hat{E}(U_{Aet_n}^*)$	$e = 3$			7,5	2,5			6,0%	2,1%
		$e = 2$		-1,7	13,2	7,6		-1,5%	10,6%	6,3%
		$e = 1$	4,2	4,8	20,7	17,3	3,8%	4,4%	16,6%	14,4%

Tabelle A.11.: Prognosefehler für unterschiedliche Varianten der additiven Methode

Die Standardmaße MSE, MAD und MAPE der Nachfrageprognosen für die Zeitpunkte t_{14} bis t_{16} mit einer Vorlaufzeit von $e = 2$ sind in Tabelle A.12 aufgeführt. Sie sind durchgängig niedriger als bei der multiplikativen Methode. Die Varianten der additiven Prognosemethode, die auf dem Schätzer $\hat{E}(U_{Aet_n})$ basieren, liefern in diesem Beispiel genauere Prognosen als die Versionen, die $\hat{E}(U_{Aet_n}^*)$ verwenden. Der MAPE errechnet sich hier für die Variante, die die exponentielle Glättung als Schätzverfahren für $\hat{E}(U_{Aet_n})$ benutzt, als durchschnittlicher Betrag aus den drei relativen Fehlerwerte von -1,5%, -0,8%

und -9,1%. Er beträgt dann 3,8%.

Arithm. Mittel	$\hat{E}(U_{\text{Aet}_n})$	MSE_{A2}	42
		MAD_{A2}	4,6
		$MAPE_{A2}$	3,9%
	$\hat{E}(U_{\text{Aet}_n}^*)$	MSE_{A2}	78
		MAD_{A2}	7,5
		$MAPE_{A2}$	6,1%
Expon. geglättet	$\hat{E}(U_{\text{Aet}_n})$	MSE_{A2}	41
		MAD_{A2}	4,5
		$MAPE_{A2}$	3,8%
	$\hat{E}(U_{\text{Aet}_n}^*)$	MSE_{A2}	78
		MAD_{A2}	7,5
		$MAPE_{A2}$	6,1%

Tabelle A.12.: Standardmaße zur Prognoseungenauigkeit für unterschiedliche Varianten der additiven Methode

A.3. Beispielhafter Einsatz der hybriden Methode

Wie bereits in Abschnitt 7.2.2.3 erwähnt, werden in diesem Abschnitt drei Versionen der hybriden Prognosemethode exemplarisch vorgeführt. Es handelt sich dabei um 2 Versionen von Guerrero und Elizondo (1997) sowie eine von Utley und May (2010). Die Tabellen A.13 und A.14 enthalten die für die Prognose relevanten Werte DD_{Aes} und DR_{Aes} für das Beispiel aus Tabelle 5.13. Es sind die beschriebenen absoluten bzw. relativen Veränderungen der kumuliert vorliegenden Bestellmenge aufeinanderfolgender Zeitpunkte. Es gilt $DD_{\text{Aet}_k} = D_{\text{Aet}_k} - D_{\text{Aet}_{k-1}}$ und $DR_{\text{Aet}_k} = D_{\text{Aet}_k} / D_{\text{Aet}_{k-1}}$.

DD_{Aes}	<i>Wunschlieferzeitpunkt</i>							
	t_1	t_2	t_3	t_4	t_5	t_6	t_7	t_8
$e = 3$		0	0	5	-10	5	5	-5
$e = 2$		5	0	0	-5	10	0	-5
$e = 1$		0	-5	10	-10	5	5	-5
$e = 0$		5	-10	10	-5	5	5	-10
	t_9	t_{10}	t_{11}	t_{12}	t_{13}	t_{14}	t_{15}	t_{16}
$e = 3$	-5	10	5	-10	5	5	5	0
$e = 2$	5	-5	15	-10	10	-5	15	5
$e = 1$	10	-5	10	-10	0	0	10	-5
$e = 0$	5	0	10	-15	10	0	15	-5

Tabelle A.13.: Absolute Veränderung der kumuliert vorliegenden Bestellmengen zu Beispiel aus Tabelle 5.13

DR_{Aes}	<i>Wunschlieferzeitpunkt</i>							
	t_1	t_2	t_3	t_4	t_5	t_6	t_7	t_8
$e = 3$		1,00	1,00	1,50	0,33	2,00	1,50	0,67
$e = 2$		1,17	1,00	1,00	0,86	1,33	1,00	0,88
$e = 1$		1,00	0,93	1,14	0,88	1,07	1,07	0,94
$e = 0$		1,05	0,90	1,11	0,95	1,05	1,05	0,91
	t_9	t_{10}	t_{11}	t_{12}	t_{13}	t_{14}	t_{15}	t_{16}
$e = 3$	0,50	3,00	1,33	0,50	1,50	1,33	1,25	1,00
$e = 2$	1,14	0,88	1,43	0,80	1,25	0,90	1,33	1,08
$e = 1$	1,13	0,94	1,13	0,89	1,00	1,00	1,13	0,94
$e = 0$	1,05	1,00	1,10	0,87	1,10	1,00	1,14	0,96

Tabelle A.14.: Relative Veränderung der kumuliert vorliegenden Bestellmengen zu Beispiel aus Tabelle 5.13

Die Schätzer für die drei unterschiedlichen Prognosemethoden zum Zeitpunkt t_{12} finden sich in Tabelle A.15. Dies beinhaltet den Schätzer für den jeweiligen y-Achsenabschnitt $\hat{\beta}_0(\dots)$ sowie die Steigung der Regressionsgeraden $\hat{\beta}_1(\dots)$. Sie wurden alle nach den in Abschnitt 7.2.2.3 in den Formeln 7.2.12 und 7.2.13 dargestellten Verfahren berechnet. Die daraus resultierenden Prognosen $DF_{Ae(t_{12}+e)}$ für Vorlaufzeiten von $e = 1$ bis $e = 3$ sind direkt darunter aufgeführt. Die Anwendung der hybriden Prognosemethoden wird in diesem Beispiel aufgrund der höheren Komplexität auf den Zeitpunkt t_{12} begrenzt.

<i>1. Methode</i>			
	$e = 1$	$e = 2$	$e = 3$
$\hat{\beta}_0(D_{Aet_{12}}, D_{A0t_{12}})$	47,60	77,19	94,55
$\hat{\beta}_1(D_{Aet_{12}}, D_{A0t_{12}})$	0,7207	0,7161	0,8182
$DF_{Ae(t_{12}+e)}$	105,25	109,42	115,00
<i>2. Methode</i>			
$\hat{\beta}_0(DD_{Aet_{12}}, DD_{A0t_{12}})$	-0,44	-0,80	0,00
$\hat{\beta}_1(DD_{Aet_{12}}, DD_{A0t_{12}})$	0,9635	0,8782	0,8333
$DF_{Ae(t_{12}+e)}$	99,56	103,59	112,50
<i>3. Methode</i>			
$\hat{\beta}_0(DR_{Aet_{12}}, DR_{A0t_{12}})$	0,2846	0,7112	0,9533
$\hat{\beta}_1(DR_{Aet_{12}}, DR_{A0t_{12}})$	0,7110	0,2797	0,0410
$DF_{Ae(t_{12}+e)}$	99,56	95,87	96,32

Tabelle A.15.: Schätzer und Prognosen für unterschiedliche Varianten der hybriden Methode

Die Berechnung der Schätzwerte wird hier exemplarisch bei einer Vorlaufzeit von $e = 2$ für die zweite Variante der Methode erläutert, die auf einer Regression der absoluten Abweichungen basiert. Dies sind die beiden Schätzwerte $\hat{\beta}_0(DD_{A2t_{12}}, DD_{A0t_{12}})$ und

$\hat{\beta}_1(DD_{A2t_{12}}, DD_{A0t_{12}})$. Aufbauend auf den Ausführungen aus Abschnitt 7.2.2.3 kann folgende Formel für die Berechnung von $\hat{\beta}_1(DD_{A2t_{12}}, DD_{A0t_{12}})$ abgeleitet werden:

$$\hat{\beta}_1(DD_{A2t_{12}}, DD_{A0t_{12}}) = \frac{CoV(t_2, t_{12}, DD_{A2s}, DD_{A0s})}{\sigma(t_2, t_{12}, DD_{A2s})^2}$$

Die Berechnung ist auf die Werte DD_{A2t_2} bis $DD_{A2t_{12}}$ begrenzt, da der Wert D_{A2t_0} nicht bekannt ist und somit DD_{A2t_1} nicht ermittelt werden kann. Die Stichprobenkovarianz kann nun einfach mit folgender Formel bestimmt werden:

$$\begin{aligned} & CoV(t_2, t_{12}, DD_{A2s}, DD_{A0s}) \\ &= \sum_{s=t_2}^{t_{12}} \frac{(DD_{A2s} - \mu(t_2, t_{12}, DD_{A2s})) \cdot (DD_{A0s} - \mu(t_2, t_{12}, DD_{A0s}))}{11-1} = 43,18 \end{aligned}$$

Da für die Varianz $\sigma(t_2, t_{12}, DD_{A2s})^2 = 49,17$ gilt, ergibt sich folgender Schätzwert:

$$\hat{\beta}_1(DD_{A2t_{12}}, DD_{A0t_{12}}) = \frac{43,18}{49,17} = 0,8782$$

Der Schätzer für den y-Achsenabschnitt $\hat{\beta}_0(DD_{A2t_{12}}, DD_{A0t_{12}})$ kann nun einfach mit folgender Formel berechnet werden:

$$\begin{aligned} \hat{\beta}_0(DD_{A2t_{12}}, DD_{A0t_{12}}) &= \mu(t_2, t_{12}, DD_{A0s}) - \hat{\beta}_1(DD_{A2t_{12}}, DD_{A0t_{12}}) \cdot \mu(t_2, t_{12}, DD_{A2s}) \\ &= 0,00 - 0,8782 \cdot 0,91 = -0,80 \end{aligned}$$

Die Ableitung des Prognosewerts $DF_{A2t_{14}}$ erfolgt direkt aus Formel 7.2.14 aus Abschnitt 7.2.2.3. Es gilt:

$$\begin{aligned} DF_{A2t_{14}} &= \left(\hat{\beta}_0(DD_{A2t_{12}}, DD_{A0t_{12}}) + \hat{\beta}_1(DD_{A2t_{12}}, DD_{A0t_{12}}) \cdot (D_{A2t_{14}} - D_{A2t_{12}}) \right) + D_{A0t_{12}} \\ &= (-0,80 + 0,8782 \cdot (45 - 40)) + 100 = 103,59 \end{aligned}$$

Das Verfahren zur Berechnung der Prognose ist bei den anderen beiden Varianten der hybriden Methode ähnlich. Bei Verwendung der ersten Variante leitet sich der Prognosewert $DF_{A2t_{14}}$ direkt aus Formel 7.2.5 ab:

$$DF_{A2t_{14}} = \hat{\beta}_0(D_{A2t_{12}}, D_{A0t_{12}}) + \hat{\beta}_1(D_{A2t_{12}}, D_{A0t_{12}}) \cdot D_{A2t_{14}} = 77,19 + 0,7161 \cdot 45 = 109,42$$

Die Anwendung der dritten Version ist komplexer. Zur Berechnung des Prognosewerts $DF_{A2t_{14}}$ ist folgende aus Formel 7.2.18 abgeleitete Gleichung zu verwenden:

$$DF_{A2t_{14}} = DRF_{A2t_{14}} \cdot DF_{A1t_{13}}$$

Die Vorhersage $DF_{A1t_{13}}$ ist separat unter Verwendung von Formel 7.2.17 zu erstellen. Alle hier benötigten Werte sind bekannt oder direkt berechenbar. Es gilt in diesem Fall $DF_{A1t_{13}} = 99,56$. Die Gleichung, um $DRF_{A2t_{14}}$ zu bestimmen, ist direkt aus Formel 7.2.16 ableitbar:

$$\begin{aligned} DRF_{A2t_{14}} &= \hat{\beta}_0 (DR_{A2t_{12}}, DR_{A0t_{12}}) + \hat{\beta}_1 (DR_{A2t_{12}}, DR_{A0t_{12}}) \cdot DR_{A2t_{14}} \\ &= 0,7112 + 0,2797 \cdot 0,90 = 0,9629 \end{aligned}$$

Der resultierende Prognosewert ist dann:

$$DF_{A2t_{14}} = 0,9629 \cdot 99,56 = 95,87$$

Entsprechend der Nummerierung der Methoden in Tabelle A.15 sind die absoluten und relativen Prognosefehler in Tabelle A.16 aufgeführt.

1. Methode			
	$e = 1$	$e = 2$	$e = 3$
$EA_{Ae(t_{12}+e)}$	4,75	0,58	10,00
$ER_{Ae(t_{12}+e)}$	4,3%	0,5%	8,0%
2. Methode			
$EA_{Ae(t_{12}+e)}$	10,44	6,41	12,50
$ER_{Ae(t_{12}+e)}$	9,5%	5,8%	10,0%
3. Methode			
$EA_{Ae(t_{12}+e)}$	10,44	14,13	28,68
$ER_{Ae(t_{12}+e)}$	9,5%	12,8%	22,9%

Tabelle A.16.: Prognosefehler für unterschiedliche Varianten der hybriden Methode

B. Detaillierte Ableitung der Kennzahlen zur Prognosegenauigkeit

In diesem Abschnitt werden die Kennzahlen zur Bewertung der Prognosegenauigkeit detailliert hergeleitet. Die Ableitung der verschiedenen Kennzahlen zur erwarteten absoluten und relativen Streuung des Prognosefehlers werden für die hybride Methode in Abschnitt B.1, für das Modell konstanter Nachfrage in Abschnitt B.2, für das Modell einer Zeitreihe mit Trend in Abschnitt B.3 und für die multiplikative Methode in Abschnitt B.4 beschrieben.

B.1. Prognosegenauigkeit der hybriden Methode

Die hybride Prognosemethode wird in Gleichung 7.2.5 wie folgt definiert: $DF_{\mathbf{A}e(t_n+e)} = \hat{\beta}_0(D_{\mathbf{A}et_n}, D_{\mathbf{A}0t_n}) + \hat{\beta}_1(D_{\mathbf{A}et_n}, D_{\mathbf{A}0t_n}) \cdot D_{\mathbf{A}e(t_n+e)}$. Die Kennzahlen werden hier speziell für das in Gleichung 7.2.12 und 7.2.13 vorgestellte Schätzverfahren der Werte $\hat{\beta}_0(D_{\mathbf{A}es}, D_{\mathbf{A}0s})$ und $\hat{\beta}_1(D_{\mathbf{A}es}, D_{\mathbf{A}0s})$ abgeleitet. Für die Analyse der Prognosegenauigkeit wird davon ausgegangen, dass die verallgemeinerten Auftragsprofile seit t_1 bis zum aktuellen Zeitpunkt t_n zur Verfügung stehen. Wie in Abschnitt 7.3.1 beschrieben, sollen für die Untersuchung der Streuung sämtliche Werte zwischen t_1 und t_n benutzt werden. Die Abweichungen der Werte zwischen t_1 und t_n von dem Regressionsmodell, auf dem die hybride Methode basiert, und deren Einfluss auf den Vorhersagefehler werden zur Bewertung der Prognosegenauigkeit verwendet. Ziel der folgenden Analyse ist es, die Prognosegenauigkeit ohne eine Initialisierung der hybriden Methode auf Basis der verallgemeinerten Auftragsprofile abzuschätzen. Für einen beliebigen Zeitpunkt t_k zwischen t_1 und t_n gilt dabei:

$$\begin{aligned} EA_{\mathbf{A}et_k} &= D_{\mathbf{A}0t_k} - DF_{\mathbf{A}et_k} \\ \Leftrightarrow EA_{\mathbf{A}et_k} &= D_{\mathbf{A}0t_k} - \hat{\beta}_0(D_{\mathbf{A}et_n}, D_{\mathbf{A}0t_n}) - \hat{\beta}_1(D_{\mathbf{A}et_n}, D_{\mathbf{A}0t_n}) \cdot D_{\mathbf{A}et_k} \end{aligned}$$

Es gilt ferner $\hat{\beta}_0(D_{\mathbf{A}et_n}, D_{\mathbf{A}0t_n}) = \mu(t_1, t_n, D_{\mathbf{A}0s}) - \hat{\beta}_1(D_{\mathbf{A}et_n}, D_{\mathbf{A}0t_n}) \cdot \mu(t_1, t_n, D_{\mathbf{A}es})$, wie in Gleichung 7.2.12 dargestellt. Daraus kann nun abgeleitet werden:

$$\begin{aligned} \Leftrightarrow EA_{\mathbf{A}et_k} &= D_{\mathbf{A}0t_k} - \left(\mu(t_1, t_n, D_{\mathbf{A}0s}) - \hat{\beta}_1(D_{\mathbf{A}et_n}, D_{\mathbf{A}0t_n}) \cdot \mu(t_1, t_n, D_{\mathbf{A}es}) \right) \\ &\quad - \hat{\beta}_1(D_{\mathbf{A}et_n}, D_{\mathbf{A}0t_n}) \cdot D_{\mathbf{A}et_k} \\ \Leftrightarrow EA_{\mathbf{A}et_k} &= (D_{\mathbf{A}0t_k} - \mu(t_1, t_n, D_{\mathbf{A}0s})) - \hat{\beta}_1(D_{\mathbf{A}et_n}, D_{\mathbf{A}0t_n}) \cdot (D_{\mathbf{A}et_k} - \mu(t_1, t_n, D_{\mathbf{A}es})) \end{aligned}$$

Wie bereits in Abschnitt 7.3.2 gezeigt, gilt für den absoluten Streuungswert:

$$\sigma(t_1, t_n, EA_{\text{Aes}}) = \sqrt{\sum_{m=t_1}^{t_n} (EA_{\text{Aem}})^2 / (n-1)}$$

Für die Streuung des Prognosefehlers gilt nun folgendes:

$$\begin{aligned} \sigma(t_1, t_n, EA_{\text{Aes}})^2 &= \sum_{j=t_1}^{t_n} (EA_{\text{Aej}})^2 / (n-1) \\ &\Leftrightarrow \sigma(t_1, t_n, EA_{\text{Aes}})^2 \\ &= \sum_{j=t_1}^{t_n} \left(D_{\text{A0j}} - \mu(t_1, t_n, D_{\text{A0s}}) - \hat{\beta}_1(D_{\text{Aet}_n}, D_{\text{A0t}_n})(D_{\text{Aej}} - \mu(t_1, t_n, D_{\text{Aes}})) \right)^2 / (n-1) \end{aligned}$$

Durch Einsatz der zweiten binomischen Formel resultiert daraus:

$$\begin{aligned} &\Leftrightarrow \sigma(t_1, t_n, EA_{\text{Aes}})^2 = \sum_{j=t_1}^{t_n} (D_{\text{A0j}} - \mu(t_1, t_n, D_{\text{A0s}}))^2 / (n-1) \\ &\quad - \sum_{j=t_1}^{t_n} 2 \cdot (D_{\text{A0j}} - \mu(t_1, t_n, D_{\text{A0s}})) \cdot \hat{\beta}_1(D_{\text{Aet}_n}, D_{\text{A0t}_n}) \cdot (D_{\text{Aej}} - \mu(t_1, t_n, D_{\text{Aes}})) / (n-1) \\ &\quad + \sum_{j=t_1}^{t_n} \left(\hat{\beta}_1(D_{\text{Aet}_n}, D_{\text{A0t}_n}) \cdot (D_{\text{Aej}} - \mu(t_1, t_n, D_{\text{Aes}})) \right)^2 / (n-1) \end{aligned}$$

Es werden nun die Formeln 3.2.2 und 5.1.7 aus den Abschnitten 3.2 bzw. 5.1.4 benutzt, um die entsprechenden Varianz- bzw. Kovarianzwerte einzufügen.

$$\begin{aligned} &\Leftrightarrow \sigma(t_1, t_n, EA_{\text{Aes}})^2 = \sigma(t_1, t_n, D_{\text{A0s}})^2 - 2 \cdot \hat{\beta}_1(D_{\text{Aet}_n}, D_{\text{A0t}_n}) \cdot CoV(t_1, t_n, D_{\text{Aes}}, D_{\text{A0s}}) \\ &\quad + \hat{\beta}_1(D_{\text{Aet}_n}, D_{\text{A0t}_n})^2 \cdot \sigma(t_1, t_n, D_{\text{Aes}})^2 \end{aligned}$$

Als nächstes wird der Schätzwert für $\hat{\beta}_1(D_{\text{Aes}}, D_{\text{A0s}})$ aus Formel 7.2.13 eingesetzt.

$$\begin{aligned} &\Leftrightarrow \sigma(t_1, t_n, EA_{\text{Aes}})^2 = \sigma(t_1, t_n, D_{\text{A0s}})^2 \\ &\quad - 2 \cdot \left(CoV(t_1, t_n, D_{\text{Aes}}, D_{\text{A0s}}) / \sigma(t_1, t_n, D_{\text{Aes}})^2 \right) \cdot CoV(t_1, t_n, D_{\text{Aes}}, D_{\text{A0s}}) \\ &\quad + \left(CoV(t_1, t_n, D_{\text{Aes}}, D_{\text{A0s}})^2 / \sigma(t_1, t_n, D_{\text{Aes}})^4 \right) \cdot \sigma(t_1, t_n, D_{\text{Aes}})^2 \end{aligned}$$

Die Werte werden nun ausmultipliziert und addiert. Anschließend wird $\sigma(t_1, t_n, D_{\text{A0s}})^2$ ausgeklammert.

$$\begin{aligned} &\Leftrightarrow \sigma(t_1, t_n, EA_{\text{Aes}})^2 = \sigma(t_1, t_n, D_{\text{A0s}})^2 - CoV(t_1, t_n, D_{\text{Aes}}, D_{\text{A0s}})^2 / \sigma(t_1, t_n, D_{\text{Aes}})^2 \\ &\Leftrightarrow \sigma(t_1, t_n, EA_{\text{Aes}})^2 = \sigma(t_1, t_n, D_{\text{A0s}})^2 \\ &\quad \cdot \left(1 - CoV(t_1, t_n, D_{\text{Aes}}, D_{\text{A0s}})^2 / \left(\sigma(t_1, t_n, D_{\text{A0s}})^2 \cdot \sigma(t_1, t_n, D_{\text{Aes}})^2 \right) \right) \end{aligned}$$

Durch Einsatz von Formel 5.1.6 aus Abschnitt 5.1.4 kann die Kennzahl nun abgeleitet werden.

$$\Leftrightarrow \sigma(t_1, t_n, EA_{\text{Aes}})^2 = \sigma(t_1, t_n, D_{\text{A0s}})^2 \cdot \left(1 - R(t_1, t_n, D_{\text{Aes}}, D_{\text{A0s}})^2 \right)$$

Eine Kennzahl für die relative Streuung kann aus den gleichen Gründen wie für die additive Methode in Abschnitt 7.3.2 nicht ermittelt werden.

B.2. Prognosegenauigkeit für Modell konstanter Nachfrage

Gemäß Formel 7.2.1 gilt für das Modell konstanter Nachfrage: $DF_{\mathbf{A}e(t_n+e)} = \hat{E}(D_{\mathbf{A}0t_n}) = \mu(t_1, t_n, D_{\mathbf{A}0s})$.

Entsprechend folgt aus $EA_{\mathbf{A}ek} = D_{\mathbf{A}0k} - DF_{\mathbf{A}ek}$ direkt $EA_{\mathbf{A}ek} = D_{\mathbf{A}0k} - \mu(t_1, t_n, D_{\mathbf{A}0s})$. Wie bereits in Abschnitt 7.3.2 gezeigt, gilt für den absoluten Streuungswert:

$$\sigma(t_1, t_n, EA_{\mathbf{A}es}) = \sqrt{\sum_{m=t_1}^{t_n} (EA_{\mathbf{A}em})^2 / (n-1)}$$

Die Kennzahl kann nun wie folgt einfach abgeleitet werden:

$$\begin{aligned} \sigma(t_1, t_n, EA_{\mathbf{A}es}) &= \sqrt{\sum_{m=t_1}^{t_n} (EA_{\mathbf{A}em})^2 / (n-1)} \\ \Leftrightarrow \sigma(t_1, t_n, EA_{\mathbf{A}es}) &= \sqrt{\sum_{m=t_1}^{t_n} (D_{\mathbf{A}0m} - \mu(t_1, t_n, D_{\mathbf{A}0s}))^2 / (n-1)} \\ \Leftrightarrow \sigma(t_1, t_n, EA_{\mathbf{A}es}) &= \sigma(t_1, t_n, D_{\mathbf{A}0s}) \end{aligned}$$

Eine Kennzahl für die relative Streuung kann aus den gleichen Gründen wie für die additive Methode in Abschnitt 7.3.2 nicht ermittelt werden.

B.3. Prognosegenauigkeit für Modell einer Zeitreihe mit Trend

Die Definition für die Prognosemethode basiert auf dem Zeitreihenmodell mit Trend, das in Gleichung 7.2.2 aufgeführt ist. Es gilt $DF_{\mathbf{A}e(t_n+e)} = \hat{\beta}_0 + \hat{\beta}_1 \cdot (t_n + e)$. Wie zuvor wird ex-post der Zeitraum zwischen den beliebigen Zeitpunkten t_1 und t_n betrachtet. Die Kennzahlen werden speziell für die bereits in den Gleichungen 4.1.7, 4.1.8 sowie 7.2.2 vorgestellten Schätzverfahren der Werte $\hat{\beta}_0$ und $\hat{\beta}_1$ abgeleitet. Es gilt also

$$\hat{\beta}_0 = \frac{\sum_{i=1}^n t_i^2 \sum_{i=1}^n D_{\mathbf{A}0i} - \sum_{i=1}^n t_i \sum_{i=1}^n t_i \cdot D_{\mathbf{A}0i}}{n \sum_{i=1}^n t_i^2 - \left(\sum_{i=1}^n t_i \right)^2}$$

$$\hat{\beta}_1 = \frac{n \sum_{i=1}^n t_i \cdot D_{A0i} - \sum_{i=1}^n t_i \sum_{i=1}^n D_{A0i}}{n \sum_{i=1}^n t_i^2 - \left(\sum_{i=1}^n t_i \right)^2}$$

Für die Analyse werden außerdem die Variablen $\mu(t_1, t_n)$ und $\sigma(t_1, t_n)$ für das arithmetische Mittel bzw. die Standardabweichung über die Zeitpunkte zwischen t_1 und t_n benötigt. $Cov(t_1, t_n, D_{A0s})$ repräsentiert zusätzlich die Kovarianz zwischen den Nachfragewerten der Zeitreihe und den jeweiligen Zeitpunkten. Der dazugehörige Korrelationskoeffizient ist $R(t_1, t_n, D_{A0s})$. Die Werte können mit folgenden Formeln berechnet werden:

$$\mu(t_1, t_n) = \frac{1}{n} \sum_{j=t_1}^{t_n} j$$

$$\sigma(t_1, t_n) = \sqrt{\sum_{j=t_1}^{t_n} (j - \mu(t_1, t_n))^2 / (n - 1)}$$

$$Cov(t_1, t_n, D_{A0s}) = \sum_{j=t_1}^{t_n} (j - \mu(t_1, t_n)) \cdot (D_{A0j} - \mu(t_1, t_n, D_{A0s})) / (n - 1)$$

$$R(t_1, t_n, D_{A0s}) = \frac{Cov(t_1, t_n, D_{A0s})}{\sigma(t_1, t_n) \cdot \sigma(t_1, t_n, D_{A0s})}$$

Für den Schätzer $\hat{\beta}_1$ gilt nun:

$$\hat{\beta}_1 = \frac{n \sum_{i=1}^n t_i \cdot D_{A0i} - \sum_{i=1}^n t_i \sum_{i=1}^n D_{A0i}}{n \sum_{i=1}^n t_i^2 - \left(\sum_{i=1}^n t_i \right)^2}$$

Durch Multiplikation von Zähler und Nenner mit $1/n^2$ resultiert hieraus:

$$\Leftrightarrow \hat{\beta}_1 = \frac{\frac{1}{n} \sum_{i=1}^n t_i \cdot D_{A0i} - \left(\frac{1}{n} \sum_{i=1}^n t_i \right) \cdot \left(\frac{1}{n} \sum_{i=1}^n D_{A0i} \right)}{\frac{1}{n} \sum_{i=1}^n t_i^2 - \left(\frac{1}{n} \sum_{i=1}^n t_i \right)^2}$$

Mit den bekannten Formeln aus der Statistik¹ kann hieraus direkt abgeleitet werden, dass der Nenner der Varianz $\sigma(t_1, t_n)^2$ und der Zähler der beschriebenen Kovarianz $Cov(t_1, t_n, D_{A0s})$ entspricht. Es gilt also:

$$\Leftrightarrow \hat{\beta}_1 = \frac{Cov(t_1, t_n, D_{A0s})}{\sigma(t_1, t_n)^2} \quad (\text{B.3.1})$$

¹Vgl. beispielsweise Bley Müller u.a. (2002, S. 39 ff.).

Währenddessen gilt für den Schätzer $\hat{\beta}_0$:

$$\hat{\beta}_0 = \frac{\sum_{i=1}^n t_i^2 \sum_{i=1}^n D_{A0i} - \sum_{i=1}^n t_i \sum_{i=1}^n t_i \cdot D_{A0i}}{n \sum_{i=1}^n t_i^2 - \left(\sum_{i=1}^n t_i \right)^2}$$

Auch hier werden Zähler und Nenner mit $1/n^2$ multipliziert. Der Nenner, der identisch mit dem für den Schätzer $\hat{\beta}_1$ ist, entspricht damit wieder der Varianz $\sigma(t_1, t_n)^2$:

$$\Leftrightarrow \hat{\beta}_0 = \frac{\frac{1}{n^2} \sum_{i=1}^n t_i^2 \sum_{i=1}^n D_{A0i} - \frac{1}{n^2} \sum_{i=1}^n t_i \sum_{i=1}^n t_i \cdot D_{A0i}}{\sigma(t_1, t_n)^2}$$

Zur Vereinfachung werden nun die beiden Erwartungswerte $\mu(t_1, t_n)$ und $\mu(t_1, t_n, D_{A0s})$ im Zähler eingesetzt:

$$\Leftrightarrow \hat{\beta}_0 = \frac{\left(\frac{1}{n} \sum_{i=1}^n t_i^2 \right) \cdot \mu(t_1, t_n, D_{A0s}) - \mu(t_1, t_n) \cdot \left(\frac{1}{n} \sum_{i=1}^n t_i \cdot D_{A0i} \right)}{\sigma(t_1, t_n)^2}$$

Der Term $\mu(t_1, t_n, D_{A0s}) \cdot \left(\frac{1}{n} \sum_{i=1}^n t_i \right)^2 - \mu(t_1, t_n, D_{A0s}) \cdot \left(\frac{1}{n} \sum_{i=1}^n t_i \right)^2$, der dem Wert 0 entspricht, wird nun im Zähler eingefügt. Gleichzeitig wird der Bruch aufgeteilt.

$$\Leftrightarrow \hat{\beta}_0 = \frac{\left(\frac{1}{n} \sum_{i=1}^n t_i^2 \right) \cdot \mu(t_1, t_n, D_{A0s}) - \mu(t_1, t_n, D_{A0s}) \cdot \left(\frac{1}{n} \sum_{i=1}^n t_i \right)^2}{\sigma(t_1, t_n)^2} + \frac{\mu(t_1, t_n, D_{A0s}) \cdot \left(\frac{1}{n} \sum_{i=1}^n t_i \right)^2 - \mu(t_1, t_n) \cdot \left(\frac{1}{n} \sum_{i=1}^n t_i \cdot D_{A0i} \right)}{\sigma(t_1, t_n)^2}$$

Durch einfache Umformung resultiert hieraus in einem ersten Schritt:

$$\Leftrightarrow \hat{\beta}_0 = \frac{\mu(t_1, t_n, D_{A0s}) \cdot \left(\left(\frac{1}{n} \sum_{i=1}^n t_i^2 \right) - \left(\frac{1}{n} \sum_{i=1}^n t_i \right)^2 \right)}{\sigma(t_1, t_n)^2} + \frac{\mu(t_1, t_n) \cdot \left(\mu(t_1, t_n, D_{A0s}) \cdot \mu(t_1, t_n) - \left(\frac{1}{n} \sum_{i=1}^n t_i \cdot D_{A0i} \right) \right)}{\sigma(t_1, t_n)^2}$$

und in einem zweiten Schritt dann:

$$\Leftrightarrow \hat{\beta}_0 = \frac{\mu(t_1, t_n, D_{A0s}) \cdot \sigma(t_1, t_n)^2}{\sigma(t_1, t_n)^2} + \frac{\mu(t_1, t_n) \cdot Cov(t_1, t_n, D_{A0s})}{\sigma(t_1, t_n)^2}$$

Hieraus kann folgende Formel für $\hat{\beta}_0$ direkt abgeleitet werden:

$$\Leftrightarrow \hat{\beta}_0 = \mu(t_1, t_n, D_{A0s}) - \hat{\beta}_1 \cdot \mu(t_1, t_n) \quad (\text{B.3.2})$$

Die folgende Umformung ähnelt nun der aus Abschnitt B.1 zur hybriden Methode stark. Analog soll die Streuung des Prognosefehlers bewertet werden, indem ex-post die Streuung der tatsächlichen Werte um das Modell einer Zeitreihe mit Trend bestimmt wird. Dies soll allerdings geschehen, ohne das Modell zu implementieren und initialisieren. Für einen beliebigen Zeitpunkt t_k zwischen t_1 und t_n gilt nun:

$$\begin{aligned} EA_{Aet_k} &= D_{A0t_k} - DF_{Aet_k} \\ \Leftrightarrow EA_{Aet_k} &= D_{A0t_k} - \hat{\beta}_0 - \hat{\beta}_1 \cdot t_k \end{aligned}$$

Durch Einfügen der soeben abgeleiteten Formel B.3.2 für $\hat{\beta}_0$ und einfaches Umformen resultiert daraus:

$$\begin{aligned} \Leftrightarrow EA_{Aet_k} &= D_{A0t_k} - \mu(t_1, t_n, D_{A0s}) + \hat{\beta}_1 \cdot \mu(t_1, t_n) - \hat{\beta}_1 \cdot t_k \\ \Leftrightarrow EA_{Aet_k} &= (D_{A0t_k} - \mu(t_1, t_n, D_{A0s})) - \hat{\beta}_1 \cdot (t_k - \mu(t_1, t_n)) \end{aligned}$$

Für den absoluten Streuungswert gilt, wie in in Abschnitt 7.3.2 dargestellt:

$$\sigma(t_1, t_n, EA_{Aes}) = \sqrt{\sum_{m=t_1}^{t_n} (EA_{Aem})^2 / (n-1)}$$

Für die Streuung des Prognosefehlers folgt nun:

$$\begin{aligned} \sigma(t_1, t_n, EA_{Aes})^2 &= \sum_{j=t_1}^{t_n} (EA_{Aej})^2 / (n-1) \\ \Leftrightarrow \sigma(t_1, t_n, EA_{Aes})^2 &= \sum_{j=t_1}^{t_n} \left((D_{A0j} - \mu(t_1, t_n, D_{A0s})) - \hat{\beta}_1 \cdot (j - \mu(t_1, t_n)) \right)^2 / (n-1) \end{aligned}$$

Durch Einsatz der zweiten binomischen Formel kann diese Formel umgeformt werden:

$$\begin{aligned} \Leftrightarrow \sigma(t_1, t_n, EA_{Aes})^2 &= \sum_{j=t_1}^{t_n} (D_{A0j} - \mu(t_1, t_n, D_{A0s}))^2 / (n-1) \\ &\quad - \sum_{j=t_1}^{t_n} 2 \cdot (D_{A0j} - \mu(t_1, t_n, D_{A0s})) \cdot \hat{\beta}_1 \cdot (j - \mu(t_1, t_n)) / (n-1) \\ &\quad + \sum_{j=t_1}^{t_n} \left(\hat{\beta}_1 \cdot (j - \mu(t_1, t_n)) \right)^2 / (n-1) \end{aligned}$$

Die zu Beginn dieses Abschnitts vorstellten Formeln zur Berechnung von Varianz- bzw. Kovarianzwerten werden nun verwendet und die entsprechenden Variablen eingefügt:

$$\Leftrightarrow \sigma(t_1, t_n, EA_{Aes}) = \sigma(t_1, t_n, D_{A0s})^2 - 2 \cdot \hat{\beta}_1 \cdot Cov(t_1, t_n, D_{A0s}) + \left(\hat{\beta}_1\right)^2 \cdot \sigma(t_1, t_n)^2$$

Anschließend wird der in Formel B.3.1 ermittelte Wert für $\hat{\beta}_1$ eingesetzt:

$$\Leftrightarrow \sigma(t_1, t_n, EA_{Aes}) = \sigma(t_1, t_n, D_{A0s})^2 - 2 \cdot \frac{Cov(t_1, t_n, D_{A0s})}{\sigma(t_1, t_n)^2} \cdot Cov(t_1, t_n, D_{A0s}) + \frac{Cov(t_1, t_n, D_{A0s})^2}{\sigma(t_1, t_n)^4} \cdot \sigma(t_1, t_n)^2$$

Es folgt die Ausmultiplikation sowie Addition der Werte und anschließend die Ausklammerung von $\sigma(t_1, t_n, D_{A0s})^2$:

$$\Leftrightarrow \sigma(t_1, t_n, EA_{Aes}) = \sigma(t_1, t_n, D_{A0s})^2 - Cov(t_1, t_n, D_{A0s})^2 / \sigma(t_1, t_n)^2$$

$$\Leftrightarrow \sigma(t_1, t_n, EA_{Aes}) = \sigma(t_1, t_n, D_{A0s})^2 \cdot \left(1 - \frac{Cov(t_1, t_n, D_{A0s})^2}{\sigma(t_1, t_n)^2 \cdot \sigma(t_1, t_n, D_{A0s})^2}\right)$$

Die Kennzahl kann nun direkt abgeleitet werden:

$$\Leftrightarrow \sigma(t_1, t_n, EA_{Aes})^2 = \sigma(t_1, t_n, D_{A0s})^2 \cdot \left(1 - R(t_1, t_n, D_{A0s})^2\right)$$

Eine Kennzahl für die relative Streuung kann aus den gleichen in Abschnitt 7.3.2 für die additive Methode erläuterten Gründen auch für das Modell einer Zeitreihe mit Trend nicht abgeleitet werden.

B.4. Prognosegenauigkeit der multiplikativen Methode

Die multiplikative Methode ist in Gleichung 7.2.3 folgendermaßen definiert: $DF_{Ae(t_n+e)} = D_{Ae(t_n+e)} / \hat{E}(X_{Aetn})$. Es wird in dieser Analyse die Annahme getroffen, dass die Zeitreihe der mit einer Vorlaufzeit von e anteilig vorliegenden Bestellmenge bis auf zufällige und identisch unabhängig verteilte Abweichungen konstant ist. Entsprechend ist das arithmetische Mittel $\mu(t_1, t_n, X_{Aes})$ als Schätzer für $\hat{E}(X_{Aetn})$ geeignet. Die Abweichungen der anteilig vorliegenden Bestellmengen zwischen t_1 und t_n von $\mu(t_1, t_n, X_{Aes})$ und deren Einfluss auf den Vorhersagefehler werden zur Bewertung der Prognosegenauigkeit verwendet. Ziel der folgenden Analyse ist es, die Prognosegenauigkeit ohne eine Initialisierung der multiplikativen Methode auf Basis der verallgemeinerten Auftragsprofile zu bestimmen. Für den absoluten Prognosefehler gilt dabei:

$$\begin{aligned}
 EA_{Aek} &= D_{A0k} - DF_{Aek} \\
 \Leftrightarrow EA_{Aek} &= D_{A0k} - D_{Aek} / \mu(t_1, t_n, X_{Aes}) \\
 \Leftrightarrow EA_{Aek} &= D_{A0k} - (D_{A0k} \cdot X_{Aek}) / \mu(t_1, t_n, X_{Aes}) \\
 \Leftrightarrow EA_{Aek} &= (D_{A0k} \cdot \mu(t_1, t_n, X_{Aes}) - D_{A0k} \cdot X_{Aek}) / \mu(t_1, t_n, X_{Aes}) \\
 \Leftrightarrow EA_{Aek} &= D_{A0k} \cdot (\mu(t_1, t_n, X_{Aes}) - X_{Aek}) / \mu(t_1, t_n, X_{Aes})
 \end{aligned}$$

Entsprechend gilt für den relativen Prognosefehler:

$$\begin{aligned}
 ER_{Aek} &= EA_{Aek} / D_{A0k} \\
 \Leftrightarrow ER_{Aek} &= (D_{A0k} \cdot (\mu(t_1, t_n, X_{Aes}) - X_{Aek}) / \mu(t_1, t_n, X_{Aes})) / D_{A0k} \\
 \Leftrightarrow ER_{Aek} &= (\mu(t_1, t_n, X_{Aes}) - X_{Aek}) / \mu(t_1, t_n, X_{Aes})
 \end{aligned}$$

Auf Basis der Annahmen aus Abschnitt 7.3.2 zum relativen Prognosefehler, die eine systematische Fehleinschätzung ausschließen, kann direkt abgeleitet werden, dass das arithmetische Mittel $\mu(t_1, t_n, ER_{Aes}) = 0$ ist.

Für die relative Streuung kann so nun folgende Streuungskennzahl bestimmt werden:

$$\begin{aligned}
 \sigma(t_1, t_n, ER_{Aes}) &= \sqrt{\sum_{m=t_1}^{t_n} (ER_{Aem})^2 / (n-1)} \\
 \Leftrightarrow \sigma(t_1, t_n, ER_{Aes}) &= \sqrt{\sum_{m=t_1}^{t_n} ((\mu(t_1, t_n, X_{Aes}) - X_{Aem}) / \mu(t_1, t_n, X_{Aes}))^2 / (n-1)} \\
 \Leftrightarrow \sigma(t_1, t_n, ER_{Aes}) &= \sqrt{\sum_{m=t_1}^{t_n} (\mu(t_1, t_n, X_{Aes}) - X_{Aem})^2 / (n-1)} / \mu(t_1, t_n, X_{Aes}) \\
 \Leftrightarrow \sigma(t_1, t_n, ER_{Aes}) &= \sigma(t_1, t_n, X_{Aes}) / \mu(t_1, t_n, X_{Aes}) \\
 \Leftrightarrow \sigma(t_1, t_n, ER_{Aes}) &= VK(t_1, t_n, X_{Aes})
 \end{aligned}$$

Die relative Streuung ist also vom Variationskoeffizienten $VK(t_1, t_n, X_{Aes})$ der anteilig vorliegenden Bestellmenge abhängig.

Die Ableitung einer Kennzahl für die absolute Streuung ist dagegen schwierig. Nach der Definition von absolutem und relativem Prognosefehler besteht folgender Zusammenhang zwischen den Streuungswerten: $\sigma(t_1, t_n, EA_{Aes}) = \sigma(t_1, t_n, ER_{Aes} \cdot D_{A0s})$. Eine Formel zur Varianzberechnung eines Produkts von zwei Zufallsvariablen wurde von Goodman (1960, 1962) eingeführt. Demnach gilt für zwei Zufallsvariablen V und W mit Erwar-

tungswerten $E(V)$ und $E(W)$:

$$\begin{aligned} Var(V \cdot W) &= E(W)^2 \cdot Var(V) + E(V)^2 \cdot Var(W) + 2E(V) \cdot E(W) \cdot CoV(V, W) \\ &\quad - CoV(V, W)^2 + E\left((V - E(V))^2 (W - E(W))^2\right) \\ &\quad + 2E(W) \cdot E\left((V - E(V))^2 (W - E(W))\right) + 2E(V) \cdot E\left((V - E(V))(W - E(W))^2\right) \end{aligned}$$

Eine Kennzahl für den absoluten Prognosefehler kann so zwar abgeschätzt werden, sie ist allerdings äußerst komplex. Sie ermöglicht entsprechend keine einfache Bewertung des zu erwartenden Prognosefehlers. Deshalb wird für die zu erwartende absolute Streuung hier keine Kennzahl bei der multiplikativen Prognosemethode bestimmt.

Literaturverzeichnis

- Alderson, W. (1950) *Marketing efficiency and the principle of postponement*, Cost and Profit Outlook, Vol. 3(4), 1–3.
- Alderson, W. (1957) *Marketing behavior and executive action*, Richard D. Irwin: Homewood.
- Alderson, W. (2006) *Marketing efficiency and the principle of postponement*, In: B. Woolliscroft; R. D. Tamilia; S. J. Shapiro (Hrsg.) *A twenty-first century guide to Aldersonian marketing thought*, Kluwer Academic Publishers: Boston u.a., 109–114.
- Amemiya, T. (1977) *The Maximum Likelihood and the Nonlinear Three-Stage Least Squares Estimator in the General Nonlinear Simultaneous Equation Model*, Econometrica, Vol. 45(4), 955–968.
- Anderson, T.; Darling, D. (1952) *Asymptotic Theory of Certain “Goodness of Fit” Criteria Based on Stochastic Processes*, Annals of Mathematical Statistics, Vol. 23(2), 193–212.
- Anthony, R. N. (1965) *Planning and Control Systems - A framework for analysis*, Havard University.
- Armstrong, J. S. (2001) *Selecting Forecasting Methods*, In: J. S. Armstrong (Hrsg.) *Principles of Forecasting: A Handbook for Researchers and Practitioners*, Kluwer Academic Publishers: Boston u.a., 365–386.
- Armstrong, J. S.; Collopy, F. (1998) *Integration of Statistical Methods and Judgment for Time Series Forecasting: Principles from Empirical Research*, In: G. Wright; P. Goodwin (Hrsg.) *Forecasting with Judgment*, John Wiley & Sons: New York u.a., 269–293.
- Aviv, Y. (2001) *The Effect of Collaborative Forecasting on Supply Chain Performance*, Management Science, Vol. 47(10), 1326–1343.
- Axsäter, S. (1986) *On the Feasibility of Aggregate Production Plans*, Operations Research, Vol. 34(5), Nr. Axsäte, 796–800, doi:<http://dx.doi.org/10.1287/opre.34.5.796>.
- Ball, M. O.; Chen, C.-Y.; Zhao, Z.-Y. (2004) *Available to Promise*, In: D. Simchi-Levi; S. D. Wu; Z.-J. Shen (Hrsg.) *Handbook of Quantitative Supply Chain Analysis – Modeling in the E-Business Era*, Kluwer Academic Publishers: Boston u.a., 447–483.
- Bera, A. K.; Jarque, C. M. (1981) *Efficient tests for normality, homoscedasticity and serial independence of regression residuals - Monte Carlo Evidence*, Economics Letters, Vol. 7(4), 313–318.

- Bestwick, P. F. (1975) *A Forecast Monitoring and Revision System for Top Management*, Operational Research Quarterly, Vol. 26(2), 419–429.
- Bitran, G. R.; Haas, E. A.; Hax, A. C. (1981) *Hierarchical Production Planning: A Single Stage System*, Operations Research, Vol. 29(4), 717–743.
- Bitran, G. R.; Haas, E. A.; Hax, A. C. (1982) *Hierarchical Production Planning: A Two-Stage System*, Operations Research, Vol. 30(2), 232–251.
- Bitran, G. R.; Hax, A. C. (1977) *On the design of hierarchical production planning systems*, Decision Sciences, Vol. 8(1), 28–55.
- Bley Müller, J.; Gehlert, G.; Gülicher, H. (2002) *Statistik für Wirtschaftswissenschaftler*, Verlag Vahlen: München, 13. Aufl.
- Bodily, S. E.; Freeland, J. R. (1988) *A Simulation of Techniques for Forecasting Shipments Using Firm Orders-to-Date*, Journal of the Operational Research Society, Vol. 39(9), 833–846.
- Box, G. E. P.; Jenkins, G. M.; Reinsel, G. C. (2008) *Time Series Analysis – Forecasting and Control*, John Wiley & Sons: New Jersey u.a.
- Box, J. F. (1987) *Guinness, Gosset, Fisher, and Small Samples*, Statistical Science, Vol. 2(1), 45–52.
- Bretschneider, S. (1986) *Estimating Forecast Variance with Exponential Smoothing*, International Journal of Forecasting, Vol. 2(3), 349–355.
- Breusch, T. (1979) *Testing for Autocorrelation in Dynamic Linear Models*, Australian Economic Papers, Vol. 17, 334–355.
- Breusch, T.; Pagan, A. (1979) *A Simple Test for Heteroscedasticity and Random Coefficient Variation*, Econometrica, Vol. 47(5), 1287–1294.
- Brown, R. G. (1959) *Statistical Forecasting for Inventory Control*, McGraw-Hill: New York u.a.
- Brown, R. G.; Meyer, R. F. (1961) *The Fundamental Theorem of Exponential Smoothing*, Operations Research, Vol. 9(5), 673–685.
- Bucklin, L. P. (1965) *Postponement, Speculation and the Structure of Distribution Channels*, Journal of Marketing Research, Vol. 2(1), 26–31.
- Bundesministerium der Finanzen (2013) *Monatsbericht des BMF – Oktober 2013*, Bundesministerium der Finanzen: Berlin.
- Carbone, R.; Armstrong, J. S. (1982) *Evaluation of Extrapolative Forecasting Methods: Results of a Survey of Academicians and Practitioners*, Journal of Forecasting, Vol. 1(2), 215–217.

- Chen, C.-Y.; Zhao, Z.-Y.; Ball, M. O. (2001) *Quantity and Due Date Quoting Available to Promise*, Information Systems Frontiers, Vol. 3(4), 477–488.
- Chen, C.-Y.; Zhao, Z.-Y.; Ball, M. O. (2002) *A model for batch advanced available-to-promise*, Production and Operations Management, Vol. 11(4), 424–440.
- Cleveland, W. S. (1979) *Robust Locally Weighted Regression and Smoothing Scatterplots*, Journal of the American Statistical Association, Vol. 74(368), 829–836.
- Cleveland, W. S.; Devlin, S. J. (1988) *Locally Weighted Regression: An Approach to Regression Analysis by Local Fitting*, Journal of the American Statistical Association, Vol. 83(403), 596–610.
- Cochrane, D.; Orcutt, G. H. (1949) *Application of Least Squares Regression to Relationships Containing Auto- Correlated Error Terms*, Journal of the American Statistical Association, Vol. 44(245), 32–61.
- Cormen, T. H.; Leiserson, C. E.; Rivest, R. L.; Stein, C. (2001) *Introduction to Algorithms*, The MIT Press: Cambridge und London, 2. Aufl.
- Croston, J. (1972) *Forecasting and Stock Control for Intermittent Demands*, Operational Research Quarterly, Vol. 23(3), 289–303.
- D'Alessandro, A. J.; Baveja, A. (2000) *Divide and Conquer: Rohm and Haas' Response to a Changing Specialty Chemicals Market*, Interfaces, Vol. 30(6), 1–16.
- Dalgaard, P. (2008) *Introductory Statistics with R*, Springer: Berlin u.a., 2. Aufl.
- Dantzig, G.; Ramser, J. (1959) *The Truck Dispatching Problem*, Management Science, Vol. 6(1), 80–91.
- de Alba, E.; Mendoza, M. (2001) *Forecasting an Accumulated Series Based on Partial Accumulation: A Bayesian Method for Short Series With Seasonal Patterns*, Journal of Business & Economic Statistics, Vol. 19(1), 95–102.
- Demski, J. S.; Feltham, G. A. (1972) *Forecast Evaluation*, Accounting Review, Vol. 47(3), 533–548.
- Domschke, W.; Scholl, A. (1999) *Grundlagen der Betriebswirtschaftslehre – Eine Einführung aus entscheidungsorientierter Sicht*, Springer: Berlin u.a., 1. Aufl.
- Domschke, W.; Scholl, A.; Voß, S. (1997) *Produktionsplanung – Ablauforganisatorische Aspekte*, Springer: Berlin u.a., 2. Aufl.
- Durbin, J.; Watson, G. (1950) *Testing for Serial Correlation in Least Squares Regression: I*, Biometrika, Vol. 37(3/4), 409–428.
- Durbin, J.; Watson, G. (1951) *Testing for Serial Correlation in Least Squares Regression. II*, Biometrika, Vol. 38(1/2), 159–177.

- Elias, R. J.; Montgomery, D. C.; Kulahci, M. (2006) *An overview of short-term statistical forecasting methods*, International Journal of Management Science and Engineering Management, Vol. 1(1), 17–36.
- Fisher, M. L. (1997) *What Is the Right Supply Chain for Your Product?*, Harvard Business Review, Vol. 75(2), 105–116.
- Fisher, R. (1921) *On the “probable error“ of a coefficient of correlation deduced from a small sample*, Metron, Vol. 1, 3–32.
- Fleischmann, B. (2008) *Distribution and Transport Planning*, In: H. Stadtler; C. Kilger (Hrsg.) *Supply Chain Management and Advanced Planning*, Springer: Berlin u.a., 4. Aufl., 231–246.
- Fleischmann, B.; Meyr, H. (2004) *Customer Orientation in Advanced Planning Systems*, In: H. Dyckhoff; R. Lackes; J. Reese (Hrsg.) *Supply Chain Management and Reverse Logistics*, Springer: Berlin u.a., 297–321.
- Fleischmann, B.; Meyr, H.; Wagner, M. (2008) *Advanced Planning*, In: H. Stadtler; C. Kilger (Hrsg.) *Supply Chain Management and Advanced Planning*, Springer: Berlin u.a., 4. Aufl., 81–106.
- Fletcher, R.; Xu, C. (1987) *Hybrid Methods for Nonlinear Least Squares*, IMA Journal of Numerical Analysis, Vol. 7(3), 371–389.
- Flidner, E. B.; Mabert, V. (1992) *Constrained Forecasting: Some Implementation Guidelines*, Decision Sciences, Vol. 23(5), 1143–1161.
- Flidner, G. (1999) *An investigation of aggregate variable time series forecast strategies with specific subaggregate time series statistical correlation*, Computers & Operations Research, Vol. 26(10/11), 1133–1149.
- Gardner, E. S. (1985) *Exponential Smoothing: The State of the Art*, Journal of Forecasting, Vol. 4(1), 1–28.
- Gardner, E. S. (2006) *Exponential Smoothing: The State of the Art - Part II*, International Journal of Forecasting, Vol. 22(4), 637–666.
- Gill, P. E.; Murray, W. (1978) *Algorithms for the Solution of the Nonlinear Least-Squares Problem*, SIAM Journal on Numerical Analysis, Vol. 15(5), 977–992.
- Glejser, H. (1969) *A New Test for Heteroskedasticity*, Journal of the American Statistical Association, Vol. 64(325), 316–323.
- Godfrey, L. (1978) *Testing Against General Autoregressive and Moving Average Error Models when the Regressors Include Lagged Dependent Variables*, Econometrica, Vol. 46(6), 1293–1301.

- Godfrey, L. (1996) *Misspecification tests and their uses in econometrics*, Journal of Statistical Planning and Inference, Vol. 49(2), 241–260.
- Goetschalckx, M.; Fleischmann, B. (2008) *Strategic Network Design*, In: H. Stadtler; C. Kilger (Hrsg.) *Supply Chain Management and Advanced Planning*, Springer: Berlin u.a., 4. Aufl., 117–132.
- Gollwitzer, M.; Karl, R. (1998) *Logistik-Controlling*, Wirtschaftsverlag Langen Müller / Herbig.
- Goodman, L. A. (1960) *On the Exact Variance of Products*, Journal of the American Statistical Association, Vol. 55(292), 708–713.
- Goodman, L. A. (1962) *The Variance of the Product of K Random Variables*, Journal of the American Statistical Association, Vol. 55(292), 708–713.
- Groër, C.; Golden, B.; Wasil, E. (2011) *A Parallel Algorithm for the Vehicle Routing Problem*, INFORMS Journal on Computing, Vol. 23(2), 315–330.
- Guerrero, V. M.; Elizondo, A. J. (1997) *Forecasting a Cumulative Variable Using Its Partially Accumulated Data*, Management Science, Vol. 43(6), 879–889.
- Haberleitner, H.; Meyr, H.; Taudes, A. (2010) *Implementation of a demand planning system using advance order information*, International Journal of Production Economics, Vol. 128(2), 518–526.
- Habla, C.; Drießel, R.; Mönch, L.; Ponsignon, T.; Ehm, H. (2007) *A Short-Term Forecast Method for Demand Quantities in Semiconductor Manufacturing*, In: *Proceedings of the 3rd Annual IEEE Conference on Automation Science and Engineering Scottsdale, AZ, USA, Sept 22-25, 2007*, 94–99.
- Handelsblatt (2011) *VW überfordert seine Zulieferer*, Online vom 26.01.2011, <http://www.handelsblatt.com/unternehmen/industrie/lieferengpass-vw-ueberfordert-seine-zulieferer/3743874.html>, abgerufen am 23.10.2013.
- Handelsblatt (2012) *GM setzt Produktion von Volt und Ampera aus*, Online vom 03.03.2012, <http://www.handelsblatt.com/unternehmen/industrie/gering-nachfrage-gm-setzt-produktion-von-volt-und-ampera-aus/6282782.html>, abgerufen am 22.10.2013.
- Hartung, J.; Elpelt, B.; Klösener, K.-H. (1998) *Statistik*, R. Oldenbourg Verlag: München und Wien, 11. Aufl.
- Hax, A. C.; Golovin, J. J. (1978) *Hierarchical production planning systems*, In: A. C. Hax (Hrsg.) *Studies in Management Science and Systems, Studies in Operations Management*, North-Holland: Amsterdam u.a., 400–428.

- Hax, A. C.; Meal, H. C. (1975) *Hierarchical integration of production planning and scheduling*, In: M. A. Geisler (Hrsg.) *Logistics, TIMS Studies in Management Science*, North-Holland: Amsterdam u.a., 53–69.
- Helms, M. M.; Ettkin, L. P.; Chapman, S. (2000) *Supply chain forecasting - Collaborative forecasting supports supply chain management*, Business Process Management Journal, Vol. 6(5), 392–407.
- Hendry, D. F.; Mizon, G. E. (1978) *Serial correlation as a convenient simplification, not a nuisance: A comment on a study of the demand for money by the Bank of England*, Economic Journal, Vol. 88, 549–563.
- Hildreth, C.; Lu, J. Y. (1960) *Demand Relations with Autocorrelated Disturbances*, Technical Bulletin 276: Michigan State University.
- Hoekstra, S.; Romme, J. (1991) *Integral Logistic Structures – Developing Customer-oriented Goods Flow*, Industrial Press: New York.
- Holt, C. C. (1957) *Forecasting seasonals and trends by exponentially weighted moving averages.*, ONR Memorandum no. 52, Carnegie Institute of Technology, Pittsburgh, PA.
- Holt, C. C. (2004) *Forecasting seasonals and trends by exponentially weighted moving averages*, International Journal of Forecasting, Vol. 20(1), 5–10.
- James, F. (2007) *Statistical Methods in Experimental Physics*, World Scientific Publishing: New Jersey u.a.
- Jarque, C. M.; Bera, A. K. (1980) *Efficient tests for normality, homoscedasticity and serial independence of regression residuals*, Economics Letters, Vol. 6(3), 255–259.
- Jarque, C. M.; Bera, A. K. (1987) *A Test for Normality of Observations and Regression Residuals*, International Statistical Review, Vol. 55(2), 163–172.
- Jeong, B.; Sim, S.-B.; Jeong, H.-S.; Kim, S.-W. (2002) *An available-to-promise system for TFT LCD manufacturing in supply chain*, Computers & Industrial Engineering, Vol. 43(1/2), 191–212.
- Jeong, I.-J. (2011) *A dynamic model for the optimization of decoupling point and production planning in a supply chain*, International Journal of Production Economics, Vol. 131(2), 561–567.
- Johansen, S.; Juselius, K. (1990) *Maximum Likelihood Estimation and Inference on Cointegration - With Applications to the Demand for Money*, Oxford Bulletin of Economics and Statistics, Vol. 52(2), 169–210.
- Johnston, F.; Boylan, J. (1996) *Forecasting for Items with Intermittent Demand*, Journal of the Operational Research Society, Vol. 47(1), 113–121.

- Kekre, S.; Morton, T. E.; Smunt, T. L. (1990) *Forecasting using partially known demands*, International Journal of Forecasting, Vol. 6(1), 115–125.
- Kendall, M.; Ord, J. K. (1990) *Time Series*, Edward Arnold a division of Hodder and Stoughton: Sevenoaks, 3. Aufl.
- Kendall, M.; Stuart, A.; Ord, J. K. (1983) *The Advanced Theory of Statistics – Volume 3 – Design and Analysis, and Time-Series*, Charles Griffin & Company Limited: London & High Wycombe, 4. Aufl.
- Kilger, C. (2008) *The Definition of a Supply Chain Project*, In: H. Stadtler; C. Kilger (Hrsg.) *Supply Chain Management and Advanced Planning*, Springer: Berlin u.a., 4. Aufl., 287–307.
- Kilger, C.; Meyr, H. (2008) *Demand Fulfilment and ATP*, In: H. Stadtler; C. Kilger (Hrsg.) *Supply Chain Management and Advanced Planning*, Springer: Berlin u.a., 4. Aufl., 181–198.
- Kilger, C.; Wagner, M. (2008) *Demand Planning*, In: H. Stadtler; C. Kilger (Hrsg.) *Supply Chain Management and Advanced Planning*, Springer: Berlin u.a., 4. Aufl., 133–160.
- Klein, R. (2008) *Genetic Algorithms*, In: H. Stadtler; C. Kilger (Hrsg.) *Supply Chain Management and Advanced Planning*, Springer: Berlin u.a., 4. Aufl., 529–536.
- Knolmayer, G.; Mertens, P.; Zeier, A. (2002) *Supply Chain Management Based on SAP Systems*, Springer: Berlin u.a.
- Krüger, M.; Böckle, M. (2007) *Kühlketten lückenlos online überwachen – Intelligente Sendungsverfolgung schließt Lücke bei unternehmensübergreifenden Transportprozessen*, In: H. J. Bullinger; M. ten Hompel (Hrsg.) *Internet der Dinge*, Springer: Berlin u.a., 273–280.
- Küsters, U. (2005) *Evaluation, Kombination und Auswahl betriebswirtschaftlicher Prognoseverfahren*, In: P. Mertens; S. Rässler (Hrsg.) *Prognoserechnung*, Physica-Verlag: Heidelberg, 6. Aufl., 367–404.
- Lambert, D. M.; Cooper, M. C.; Pagh, J. D. (1998) *Supply Chain Management: Implementation Issues and Research Opportunities*, International Journal of Logistics Management, Vol. 9(2), 1–20.
- Lawrence, M.; Edmundson, R.; O'Connor, M. (1986) *The Accuracy of Combining Judgemental and Statistical Forecasts*, Management Science, Vol. 32(12), 1521–1532.
- Lee, H. L.; Tang, C. S. (1997) *Modelling the Costs and Benefits of Delayed Product Differentiation*, Management Science, Vol. 43(1), 40–53.
- Lee, Y. M.; Connors, D. (2006) *Forecasting Workforce Demand Using Partially Known Demand Information and Lead Time*, In: *Presentation at the INFORMS International Conference, June 25-28, 2006, Hongkong, China*.

- Levenberg, K. (1944) *A method for the solution of certain problems in least squares*, Quarterly of Applied Mathematics, Vol. 2, 164–168.
- Macaulay, F. R. (1931) *The Smoothing of Time Series*, National Bureau of Economic Research: New York u.a.
- Makridakis, S.; Wheelwright, S. C. (1989) *Forecasting Methods for Management*, John Wiley & Sons: New York u.a., 5. Aufl.
- Makridakis, S.; Wheelwright, S. C.; Hyndman, R. J. (1998) *Forecasting - Methods and Applications*, John Wiley & Sons: New York u.a., 3. Aufl.
- Marquardt, D. W. (1963) *An Algorithm for Least-Squares Estimation of Nonlinear Parameters*, Journal of the Society for Industrial and Applied Mathematics, Vol. 11(2), 431–441.
- Mason-Jones, R.; Towill, D. R. (1999) *Using the Information Decoupling Point to Improve Supply Chain Performance*, International Journal of Logistics Management, Vol. 10(2), 13–26.
- McClave, J. T.; Benson, P. G.; Sincich, T. (2005) *Statistics – For Business and Economics*, Pearson Prentice Hall: Upper Saddle River, 9. Aufl.
- Mendoza, M.; de Alba, E. (2006) *Forecasting an accumulated series based on partial accumulation II: A new Bayesian method for short series with stable seasonal patterns*, International Journal of Forecasting, Vol. 22(4), 781–798.
- Meyr, H. (2003) *Die Bedeutung von Entkopplungspunkten für die operative Planung von Supply Chains*, Zeitschrift für Betriebswirtschaftslehre, Vol. 73(9), 941–962.
- Meyr, H. (2004) *Supply chain planning in the German automotive industry*, OR Spectrum, Vol. 26(4), 447–470.
- Meyr, H. (2008) *Forecast Methods*, In: H. Stadtler; C. Kilger (Hrsg.) *Supply Chain Management and Advanced Planning*, Springer: Berlin u.a., 4. Aufl., 505–516.
- Meyr, H. (2012) *Demand Planning (DP)*, In: H. Stadtler; B. Fleischmann; M. Grunow; H. Meyr; C. Sürie (Hrsg.) *Advanced Planning in Supply Chains – Illustrating the Concepts Using an SAP® APO Case Study*, Springer: Berlin u.a., 67–108.
- Meyr, H.; Rosič, H.; Seipl, C.; Wagner, M.; Wetterauer, U. (2008a) *Architecture of Selected APS*, In: H. Stadtler; C. Kilger (Hrsg.) *Supply Chain Management and Advanced Planning*, Springer: Berlin u.a., 4. Aufl., 349–366.
- Meyr, H.; Stadtler, H. (2008) *Types of Supply Chains*, In: H. Stadtler; C. Kilger (Hrsg.) *Supply Chain Management and Advanced Planning*, Springer: Berlin u.a., 4. Aufl., 65–80.

- Meyr, H.; Wagner, M.; Rohde, J. (2008b) *Structure of Advanced Planning Systems*, In: H. Stadtler; C. Kilger (Hrsg.) *Supply Chain Management and Advanced Planning*, Springer: Berlin u.a., 4. Aufl., 109–115.
- Mood, A. M.; Graybill, F. A.; Boes, D. C. (1974) *Introduction to theory of statistics*, McGraw-Hill Kogakusha: Tokyo u.a., 3. Aufl.
- Moré, J. J. (1978) *The Levenberg-Marquardt algorithm: Implementation and theory*, In: G. A. Watson (Hrsg.) *Lecture Notes in Mathematics 630/1978 - Numerical Analysis*, Springer: Berlin u.a., 105–116.
- Myung, J. (2003) *Tutorial on maximum likelihood estimation*, Journal of Mathematical Psychology, Vol. 47(1), 90–100.
- Nocedal, J.; Wright, S. J. (2006) *Numerical Optimization*, Springer: Berlin u.a., 2. Aufl.
- Nowack, A. (2005) *Prognose bei unregelmäßigem Bedarf*, In: P. Mertens; S. Rässler (Hrsg.) *Prognoserechnung*, Physica-Verlag: Heidelberg, 6. Aufl., 61–72.
- Olhager, J. (2003) *Strategic positioning of the order penetration point*, International Journal of Production Economics, Vol. 85(3), 319–329.
- Olhager, J. (2010) *The role of the customer order decoupling point in production and supply chain management*, Computers in Industry, Vol. 61(9), 863–868.
- Park, R. (1966) *Estimation with Heteroscedastic Error Terms*, Econometrica, Vol. 34(4), 888.
- Pearson, E.; Hartley, H. (1976a) *Biometrika Tables for Statisticians – Volume I*, Biometrika Trust: London, 3. Aufl.
- Pearson, E.; Hartley, H. (1976b) *Biometrika Tables for Statisticians – Volume II*, Biometrika Trust: London.
- Pibernik, R. (2005) *Advanced available-to-promise: Classification, selected methods and requirements for operations and inventory management*, International Journal of Production Economics, Vol. 93-94, 239–252.
- Pillac, V.; Gendreau, M.; Guéret, C.; Medaglia, A. L. (2013) *A review of dynamic vehicle routing problems*, European Journal of Operational Research, Vol. 225(1), 1–11.
- Porter, M. E. (2014) *Wettbewerbsvorteile*, Campus Verlag: Frankfurt am Main, 12. Aufl.
- Ramanathan, R. (2002) *Introductory Econometrics with Applications*, South-Western Thomson Learning: Mason u.a., 5. Aufl.
- Ramberg, J. (2011) *ICC Guide to Incoterms® 2010 - Understanding and practical use*, International Chamber of Commerce: Paris.

- Rambo, W. W.; Chomiak, A. M.; Price, J. M. (1983) *Consistency of Performance Under Stable Conditions of Work*, Journal of Applied Psychology, Vol. 68(1), 78–87.
- Rao, A. V. (1973) *A Comment on: Forecasting and Stock Control for Intermittent Demands*, Operational Research Quarterly, Vol. 24(4), 639–640.
- Rei, W.; Gendreau, M.; Soriano, P. (2010) *A Hybrid Monte Carlo Local Branching Algorithm for the Single Vehicle Routing Problem with Stochastic Demands*, Transportation Science, Vol. 44(1), 136–146.
- RiskMetrics (1996) *RiskMetrics(TM)-Technical Document*, Tech. rep., J.P. Morgan/Reuters.
- Rogers, D. F.; Plante, R. D.; Wong, R. T.; Evans, J. R. (1991) *Aggregation and disaggregation techniques and methodology in optimization*, Operations Research, Vol. 39(4), 553–582.
- Rohde, J.; Meyr, H.; Wagner, M. (2000) *Die Supply Chain Planning Matrix*, PPS Management, Vol. 5(1), 10–15.
- Rohde, J.; Wagner, M. (2008) *Master Planning*, In: H. Stadtler; C. Kilger (Hrsg.) *Supply Chain Management and Advanced Planning*, Springer: Berlin u.a., 4. Aufl., 161–179.
- Roitsch, M.; Meyr, H. (2008) *Oil Industry*, In: H. Stadtler; C. Kilger (Hrsg.) *Supply Chain Management and Advanced Planning*, Springer: Berlin u.a., 4. Aufl., 399–414.
- Schneck, O. (2007) *Lexikon der Betriebswirtschaftslehre*, Deutscher Taschenbuch Verlag, 7. Aufl.
- Schneeweiss, C. (2003) *Distributed Decision Making*, Springer: Berlin u.a., 2. Aufl.
- Schröder, M. (2005) *Einführung in die kurzfristige Zeitreihenprognose und Vergleich der einzelnen Verfahren*, In: P. Mertens; S. Rässler (Hrsg.) *Prognoserechnung*, Physica-Verlag: Heidelberg, 6. Aufl., 7–38.
- Shapiro, S.; Francia, R. (1972) *An Approximate Analysis of Variance Test for Normality*, Journal of the American Statistical Association, Vol. 67(337), 215–216.
- Shapiro, S.; Wilk, M. (1965) *An Analysis of Variance Test for Normality (complete samples)*, Biometrika, Vol. 52(3/4), 591–611.
- Sharman, G. (1984) *The rediscovery of logistics*, Harvard Business Review, Vol. 62(5), 71–79.
- Shiskin, J.; Young, A. H.; Musgrave, J. C. (1967) *The X-11 variant of the census method II seasonal adjustment program*, Tech. Rep. 15, Bureau of the Census.
- Silver, E. A.; Pyke, D. F.; Peterson, R. (1998) *Inventory Management and Production Planning and Scheduling*, John Wiley & Sons: New Jersey u.a., 3. Aufl.

- Silver, N. C.; Dunlap, W. P. (1987) *Averaging Correlation Coefficients: Should Fisher's z Transformation Be Used?*, Journal of Applied Psychology, Vol. 72(1), 146–148.
- Stadtler, H. (1986) *Hierarchical Production Planning: Tuning aggregate planning with sequencing and scheduling*, In: S. Axsäter; C. Schneeweiss; E. Silver (Hrsg.) *Lecture Notes in Economics and Mathematical Systems vol. 266, Multi-Stage Production Planning and Inventory Control*, Springer: Berlin u.a., 197–226.
- Stadtler, H. (2008a) *Linear and Mixed Integer Programming*, In: H. Stadtler; C. Kilger (Hrsg.) *Supply Chain Management and Advanced Planning*, Springer: Berlin u.a., 4. Aufl., 517–527.
- Stadtler, H. (2008b) *Production Planning and Scheduling*, In: H. Stadtler; C. Kilger (Hrsg.) *Supply Chain Management and Advanced Planning*, Springer: Berlin u.a., 4. Aufl., 199–216.
- Stadtler, H. (2008c) *Purchasing and Material Requirements Planning*, In: H. Stadtler; C. Kilger (Hrsg.) *Supply Chain Management and Advanced Planning*, Springer: Berlin u.a., 4. Aufl., 217–230.
- Stadtler, H. (2008d) *Supply Chain Management - An Overview*, In: H. Stadtler; C. Kilger (Hrsg.) *Supply Chain Management and Advanced Planning*, Springer: Berlin u.a., 4. Aufl., 9–36.
- Stadtler, H.; Fleischmann, B. (2012) *Hierarchical Planning and the Supply Chain Planning Matrix*, In: H. Stadtler; B. Fleischmann; M. Grunow; H. Meyr; C. Sürie (Hrsg.) *Advanced Planning in Supply Chains – Illustrating the Concepts Using an SAP® APO Case Study*, Springer: Berlin u.a., 21–34.
- Student (1908a) *Probable error of a correlation coefficient*, Biometrika, Vol. 6(2/3), 302–310.
- Student (1908b) *The probable error of a mean*, Biometrika, Vol. 6(1), 1–25.
- Tan, T. (2008) *Using imperfect advance demand information in forecasting*, IMA Journal of Management Mathematics, Vol. 19(2), 163–173.
- Taylor, J. W. (2006) *Invited Comments on “Exponential Smoothing: The State of the Art - Part II” by E.S. Gardner*, International Journal of Forecasting, Vol. 22(4), 671–672.
- Tempelmeier, H. (2008) *Material-Logistik*, Springer: Berlin u.a., 7. Aufl.
- Toth, P.; Vigo, D. (2001) *The Vehicle Routing Problem*, SIAM Monographs on Discrete Mathematics and Applications.
- Turnage, J. J.; Muchinsky, P. M. (1984) *A Comparison of the Predictive Validity of Assessment Center Evaluations Versus Traditional Measures in Forecasting Supervisory Job Performance: Interpretive Implications of Criterion Distortion for the Assessment Paradigm*, Journal of Applied Psychology, Vol. 69(4), 595–602.

- Utley, J. S.; May, J. G. (2010) *The use of advance order data in demand forecasting*, Operations Management Research, Vol. 3(1/2), 33–42.
- van Donk, D. P. (2001) *Make to stock or make to order: The decoupling point in the food processing industries*, International Journal of Production Economics, Vol. 69(3), 297–306.
- van Donselaar, K.; Kopczak, L. R.; Wouters, M. (2001) *The use of advance demand information in a project-based supply chain*, European Journal of Operational Research, Vol. 130(3), 519–538.
- Vogel, S. (2014) *Demand Fulfillment in Multi-Stage Customer Hierarchies*, Springer Gabler: Wiesbaden.
- Vollmann, T. E.; Berry, W. L.; Whybark, D. C. (1992) *Manufacturing Planning and Control Systems*, Irwin: Burr Ridge u.a., 3. Aufl.
- Vollmann, T. E.; Berry, W. L.; Whybark, D. C.; Jacobs, F. R. (2005) *Manufacturing Planning and Control for Supply Chain Management*, McGraw-Hill: Boston u.a., 5. Aufl.
- Wedekind, H. (1968) *Ein Vorhersagemodell für sporadische Nachfragemengen bei der Lagerhaltung*, Ablauf- und Planungsforschung, Vol. 9(1), 1–11.
- White, H. (1980) *A Heteroskedasticity-Consistent Covariance Matrix Estimator and a Direct Test for Heteroskedasticity*, Econometrica, Vol. 48(4), 817–838.
- Winters, P. R. (1960) *Forecasting Sales by Exponentially Weighted Moving Averages*, Management Science, Vol. 6(3), 324–342.
- Zotteri, G.; Kalchschmidt, M.; Caniato, F. (2005) *The impact of aggregation level on forecasting performance*, International Journal of Production Economics, Vol. 93/94, 479–491.

Curriculum Vitae

Robert Zander

Persönliche Angaben

Geburtstag und -ort: 18.12.1978 in Berlin, Deutschland

Staatsangehörigkeit: Deutsch

Akademische Ausbildung

Okt. 2010 – Apr. 2016: Doktorand
Fachbereich Rechts- und Wirtschaftswissenschaften
Prof. Dr. Herbert Meyr
Technische Universität Darmstadt, Darmstadt, Deutschland

Okt. 2000 – Jun. 2007: Diplomstudiengang Wirtschaftsinformatik
Technische Universität Darmstadt, Darmstadt, Deutschland

Aug. 2004 – Mai 2005: Studienaustausch Fachbereich Informatik
University of Massachusetts, Amherst, USA

Jun. 1999: Abitur
Gymnasium Freiherr-vom-Stein-Schule, Frankfurt am Main,
Deutschland